

UNIVERSIDAD COMPLUTENSE DE MADRID

FACULTAD DE INFORMÁTICA

Departamento de Ingeniería del Software e Inteligencia Artificial



**PERCEPCIÓN Y ACTUACIÓN PARA EL
TRATAMIENTO SELECTIVO DE MALAS
HIERBAS EN TIEMPO REAL.**

**MEMORIA PARA OPTAR AL GRADO DE DOCTOR
PRESENTADA POR**

Xavier Paolo Burgos Artizzu

Bajo la dirección de los doctores

Ángela Ribeiro Seijas
Gonzalo Pajares Martisanz

Madrid, 2010

- ISBN: 978-84-693-3464-5

UNIVERSIDAD COMPLUTENSE DE MADRID

FACULTAD DE INFORMÁTICA

Departamento de Ingeniería del Software e Inteligencia Artificial



TESIS DOCTORAL

Percepción y Actuación para el
Tratamiento Selectivo de Malas Hierbas
en Tiempo Real

Xavier Paolo Burgos Artizzu

Madrid, 2009

UNIVERSIDAD COMPLUTENSE DE MADRID

FACULTAD DE INFORMÁTICA

Departamento de Ingeniería del Software e Inteligencia Artificial



TESIS DOCTORAL

Percepción y Actuación para el
Tratamiento Selectivo de Malas Hierbas
en Tiempo Real

Autor: Xavier Paolo Burgos Artizzu
Ingeniero en Informática

Directores: Dra. Ángela Ribeiro Seijas
Doctora en Ciencias Físicas

Dr. Gonzalo Pajares Martinsanz
Doctor en Ciencias Físicas

Madrid, 2009

No creas en lo que has oído.

No creas en la tradición porque provenga de muchas generaciones.

No creas en nada de lo que se ha hablado muchas veces.

No creas en algo porque haya sido escrito por algún viejo sabio.

No creas en las conjeturas.

No creas en la autoridad, en los maestros o en los ancianos.

*Cuando hayas observado y analizado detenidamente una cosa,
que esté de acuerdo con la razón y beneficie a uno y a todos;
entonces acéptala y vive conforme a ella.*

Siddhartha Gautama, (Buda)

(563 a.C.- 483 a.C.)

A mia mamma, per i suoi consigli, il suo affetto, ottimismo e vitalità

A mi padre, por sus preguntas, su apoyo, ingenio y sentido del humor

Agradecimientos

Lo primero es lo primero. Este trabajo nunca habría sido posible sin mi directora, la Dra. D^a Ángela Ribeiro, que desde el principio creyó en mí, dándome la posibilidad de trabajar en lo que me gusta, y que a lo largo de estos años ha sabido al mismo tiempo dirigirme y dejarme en libertad. Gracias por tu ayuda, tus inestimables consejos, por enseñarme todo lo que sabes y por reírte en lugar de desesperarte cuando ves que me invento palabras...

Del mismo modo, quiero agradecer a mi segundo director, el Dr. D. Gonzalo Pajares. La aventura empezó en su despacho, cuándo aparecí como un pavo sin cabeza preguntando por investigación en robótica, sin siquiera haber acabado los últimos exámenes de la carrera. El enseguida me “adoptó” y me puso en contacto con Ángela. Desde entonces, gracias a tu ayuda, confianza y ánimos todo ha sido mucho más fácil.

A todo el personal técnico y de apoyo del Instituto de Automática Industrial del CSIC, y en especial a los directores Dr. D. Salvador Ros y Dr. D. Manuel Armada, a los investigadores del grupo GPA, Dr. D^a María García-Alegre y Dr. D. Domingo Guinea y al Dr. D. José Javier Anaya. Gracias por vuestra profesionalidad, por el apoyo y por todas las facilidades brindadas.

Al Dr. D. César Fernández-Quintanillas, Dr. D. José Dorado y D. Dionisio Andújar del Instituto de Ciencias Agrarias del CSIC, por su ayuda con toda la parte agrónoma y medio ambiental, base principal de esta tesis.

A D. Pedro Hernaíz y a todo el equipo de la finca de la Poveda. Gracias por vuestra paciencia a la hora de soportar todos los retrasos en fechas de tratamiento que os hemos causado todos estos años, y por la ayuda en todas las pruebas realizadas en el campo.

A los profesores de la Facultad de Informática de la UCM Dra. D^a Matilde Santos, Dra. D^a Belén Díaz y Dr. D. Fernando Sáenz, que supieron aconsejarme al acabar la carrera, cuando más lo necesitaba, y que han seguido apoyandome a través de las asignaturas y trabajos del Doctorado.

A todo el personal del National Centre for Engineering in Agriculture en Australia, el Dr. D. John Billingsley, D. Steve Rees, D. Troy Symes, D. Craig Baillie, D. Erik Schmidt y D^a Sue Sutherland, que hicieron de mi estancia allí algo inolvidable tanto en lo personal como en lo profesional. A todo el personal de la empresa Bundaberg Sugar, por su colaboración en todas las pruebas en el campo.

Al CSIC y al Ministerio de Educación y Ciencia por la financiación de esta tesis a través de una beca del programa de Formación de Personal Investigador I3P (BOE 27/07/06) y a la CICYT por la financiación de los desplazamientos y el material a través de los proyectos (AGL2005-06180-C03-00 y AGL2008-04670-C03-01).

Resumen

Tradicionalmente, las prácticas de cultivo se han orientado hacia una gestión uniforme del campo, ignorando la variabilidad espacial y temporal, debido al alto coste que supone un tratamiento desigual. Es decir, todo el campo se trata del mismo modo todos los años, a pesar de que puede presentar necesidades distintas según la zona o de un año a otro.

En los últimos años, se ha producido un importante avance con la aplicación de sistemas de control y automatización en agricultura, apareciendo el concepto de **Agricultura de Precisión (AP)**. Uno de los aspectos más importantes de la AP son las técnicas orientadas a la aplicación selectiva de tratamientos, que proponen ajustar las dosis de herbicidas a las necesidades de cada unidad de terreno, traducándose en una reducción de los costes de producción y una gestión agrícola más respetuosa con el medioambiente.

Para ser capaces de ajustar las dosis de herbicidas a las necesidades de cada unidad de terreno, primero se deben localizar las distintas especies de malas hierbas (etapa de Percepción), y a continuación se debe realizar la aplicación de tratamientos de modo que se eliminen todas las malas hierbas encontradas, minimizando el uso de productos fitosanitarios (etapa de Actuación). En esta tesis se presentan nuevos métodos tanto de Percepción como de Actuación para una aplicación selectiva de tratamientos automática, precisa y barata.

Los métodos de Percepción desarrollados son capaces, mediante técnicas de Visión Artificial, de estimar las densidades de cultivo, malas hierbas y suelo tanto en fotos del campo (sin restricciones en tiempo de cómputo) como en vídeos adquiridos por

una cámara instalada directamente sobre el tractor y procesados en tiempo real. Dichos métodos hacen frente a las dificultades producidas por la inmensa variabilidad encontrada en el campo (distintos estados de crecimiento de la vegetación, errores de sembrado, densidad variable de la infestación, etc.) y por el hecho de trabajar en exteriores (iluminación cambiante y difícil de controlar). Los métodos han sido probados sobre un conjunto grande de imágenes y vídeos tomados a lo largo de los últimos cuatro años en varios campos, demostrando ser capaces de extraer los elementos naturales con gran precisión y de forma robusta.

La información recogida en la etapa de Percepción se pasa a un controlador borroso, que, haciendo uso de conocimiento experto, permite calcular la dosis óptima de herbicida a aplicar en cada unidad del terreno en función de las densidades presentes de infestación y cultivo. La aplicación de dicha dosis se realiza de forma automática, actuando sobre el equipo de tratamiento, automatizado para su control desde un ordenador a través de una tarjeta de adquisición de datos y el circuito electrónico diseñado a medida.

Una vez integradas todas las partes, se ha simulado la aplicación selectiva de tratamientos sobre campos reales. Partiendo de muestreos fotográficos discretos llevados a cabo en los últimos tres años en distintos campos, se han alcanzado ahorros medios de herbicida del 76 % con picos del 93 %, poniendo de manifiesto el claro beneficio de la aplicación de las técnicas propuestas.

Palabras Clave

Visión artificial, Procesamiento de imágenes, Agricultura de precisión, Detección de malas hierbas, Tiempo real, Algoritmos evolutivos, Razonamiento basado en casos, Automatización, Control borroso, Sistemas expertos, Sistemas de aplicación selectiva de tratamientos

Abstract

Traditionally, management of agricultural fields has not taken into account existing spatial and temporal variability, and herbicides have been applied to a crop in a uniform manner, regardless of site conditions. All the field is treated the same way every year, even though each area shows different conditions each year.

In the last years, important advances have been made thanks to the appearance of **Precision Agriculture (PA)**, a concept that addresses the in-field variability of factors that influence crop growth, through the application of control systems and automation in agriculture. One of the most important goals of PA is site-specific management practices, which seek to adjust the herbicide dosage to the amount of weed present at each field unit. The benefits of site-specific management include a cost reduction to produce the crop and a reduction in environmental pollution.

In order to adjust the herbicide dosage to the needs of each field unit, it is essential to know the degree of weed coverage in each area of the field (Data collection stage) and to plan the herbicide spraying accordingly (Interpretation/Application stage). In this thesis, novel Data collection and Interpretation/Application methods are presented, leading to an automatic, precise and cheap site-specific management of weeds.

The developed Computer Vision-based data collection methods are able to estimate weed, crop and soil percentages both from still images of the field (processed without time restrictions) and from videos taken by a camera placed directly on the tractor and processed in real-time. In this context, the main challenge in terms of image analysis is to achieve an appropriate discrimination among weed, crop and soil in outdoor field images under varying conditions of illumination, soil background texture, crop damage

and weed patchiness. The proposed methods have been tested on a wide variety of images and videos taken in different crop fields during the last four years, performing a robust and precise discrimination.

The information gathered in the data collection stage is then passed to a fuzzy controller that determines the optimal dosage of herbicide for each field unit, based on the computed weed and crop coverages, using expert knowledge. The desired dosage is applied controlling the spraying bar from a computer, through a data acquisition card and the custom-made electronic circuit.

Once all the parts finished, the site-specific spraying system's use was simulated on real crop fields, starting from photographic samplings carried out during the last three years in different fields. The results show mean herbicide savings of 76 % and up to 93 % in the best cases, clearly showing the benefits of the site-specific management techniques proposed.

Keywords

Computer vision, Image processing, Precision agriculture, Weed detection, Real-time, Evolutionary algorithms, Case based reasoning, Automation, Fuzzy control, Expert systems, Site specific management systems

Índice general

1. Introducción	1
1.1. Aplicación selectiva de tratamientos	1
1.2. Motivación y objetivos	3
1.2.1. Motivación	3
1.2.2. Objetivos	4
1.2.3. Principales hitos a alcanzar	5
1.3. Estructura de la tesis	6
 I Estado del arte	 9
 2. Agricultura de Precisión	 11
2.1. El papel de la agricultura en la sociedad y el medio ambiente	11
2.2. Agricultura de Precisión	15
2.3. Tratamiento selectivo de malas hierbas	24
2.3.1. Estudio de la ecología espacio-temporal de las malas hierbas . . .	26
2.3.2. Detección y muestreo de malas hierbas (Percepción)	28
2.3.3. Aplicación selectiva de tratamientos (Actuación)	34
 3. Visión Artificial aplicada a la agricultura	 39
3.1. Introducción a la Visión Artificial	39
3.2. Fundamentos de la Visión Artificial	46
3.2.1. Adquisición de imágenes digitales	47
3.2.2. Formación de imágenes digitales	49
3.2.3. Procesamiento	53
3.3. Visión Artificial y agricultura	58

3.4. Muestreo de malas hierbas mediante Visión Artificial	64
II Sistema autónomo de aplicación de herbicida	73
4. Estimación de la cobertura de malas hierbas en muestreos fotográficos	75
4.1. Etapas y métodos del procesamiento de imágenes y plataforma de gestión de imágenes	80
4.1.1. Segmentación	82
4.1.2. Eliminación de las líneas de cultivo	91
4.1.3. Filtrado de las malas hierbas	104
4.1.4. Plataforma de gestión de imágenes	112
4.2. Ajuste del procesamiento de imágenes mediante algoritmos genéticos . .	116
4.2.1. Ajuste mediante un algoritmo genético simple o estándar	119
4.2.2. Ajuste mediante <i>NSGA-II</i>	131
4.3. Ajuste del procesamiento en función de las características de cada imagen	142
4.3.1. Arquitectura del sistema	148
4.3.2. Indexación de los casos	149
4.3.3. Estructura de los casos y de la base de casos	153
4.3.4. Recuperación	155
4.3.5. Adaptación	157
4.3.6. Aprendizaje	158
4.3.7. Resultados	158
5. Detección de malas hierbas en tiempo real	163
5.1. Detección de malas hierbas en tiempo real en maíz	164
5.1.1. Adquisición de imágenes	165
5.1.2. Procesamiento propuesto	170
5.1.3. Resultados	179
5.2. Detección de malas hierbas en tiempo real en caña de azúcar	183
5.2.1. Adquisición de las imágenes	185
5.2.2. Procesamiento	186
5.2.3. Conclusiones	200
6. Actuación	205
6.1. Equipos de tratamiento y técnicas de pulverización	206

ÍNDICE GENERAL

6.1.1. Equipos autónomos de tratamiento	211
6.2. Automatización de la barra de tratamientos	214
6.2.1. Descripción de los componentes del sistema	214
6.2.2. Circuito electrónico de control	218
6.2.3. Pruebas en laboratorio	226
6.3. Controlador borroso multivariable para el ajuste de tratamientos	229
6.3.1. Requisitos del controlador	229
6.3.2. Descripción del controlador borroso propuesto	231
6.3.3. Resultados	240
III Conclusiones y trabajo futuro	251
7. Conclusiones y líneas de investigación futuras	253
7.1. Conclusiones más relevantes	254
7.1.1. Percepción	254
7.1.2. Actuación	257
7.2. Principales aportaciones y divulgación	258
7.3. Líneas de investigación futura	259
7.3.1. Métodos de percepción en imágenes	260
7.3.2. Métodos de percepción en tiempo real	261
7.3.3. Actuación	262
7.3.4. Otras líneas de investigación y proyectos asociados	263
7.4. Transferencia de tecnología	264
7.4.1. Patentes industriales	265
7.4.2. Registros comerciales	265
Bibliografía	267

Índice de figuras

2.1. Evolución del empleo mundial por sectores	12
2.2. Ciclo de la Agricultura de Precisión	18
2.3. Diagrama de flujo de la AP	19
2.4. Ejemplo de mapas de infestación	28
2.5. Distintos tamaños de malla de muestreo	29
3.1. El espectro electromagnético	42
3.2. Visión estéreo usada por el robot Spirit en Marte	45
3.3. Tareas principales de la VA	46
3.4. Ejemplo de sensores CCD y CMOS	48
3.5. Esquema de funcionamiento de los sensores CCD y CMOS	49
3.6. Imagen digital como matriz de píxeles	50
3.7. Resolución de una imagen (número de píxeles)	50
3.8. Profundidad de los píxeles	51
3.9. Formación de una imagen RGB	52
3.10. El filtro de Bayer	53
3.11. Comparación de la percepción de los distintos colores del ojo humano frente a las cámaras	54
3.12. Adquisición y formación de una imagen digital	55
3.13. Reconocimiento e identificación de objetos en una imagen	58
3.14. VA en semilleros	59
3.15. Procesamiento de imágenes para la recolección automática de frutas	60
3.16. Ejemplos de métodos de guiado de tractores mediante VA	62
3.17. Variabilidad de condiciones en el campo	63
3.18. Segmentación de vegetación en imágenes pertenecientes a distintos tipos de cultivo	66

3.19. Imágenes de distintos cultivos y especies de malas hierbas	68
3.20. Discriminación mediante redes neuronales y wavelets	70
4.1. Las infestaciones encontradas crecen en forma de rodales	77
4.2. Método de toma de las imágenes de muestreo	78
4.3. Ejemplo de imágenes de entrada	79
4.4. Etapas en el procesamiento de imágenes naturales	81
4.5. Resultados de la combinación lineal de los planos RGB (S1)	85
4.6. Resultado de la binarización de la imagen (S1)	87
4.7. Determinación de gama de colores mediante la definición de la relevancia en los planos RGB	88
4.8. Efecto de imponer límites sobre la luminosidad y sombras de un deter- minado color	89
4.9. Resultados de S2	90
4.10. Resultados de E1	93
4.11. Resultados de E1 sobre una imagen infestada	94
4.12. Presencia de píxeles negros aislados dentro de las líneas de cultivo . . .	95
4.13. Resultados de E2	96
4.14. Resultados de E2 sobre una imagen infestada	96
4.15. Uso del cambio de niveles de intensidad para la extracción de bordes . .	98
4.16. Extracción de bordes con distinta dirección de gradiente	100
4.17. Caracterización de las líneas de cultivo mediante operadores de borde .	101
4.18. Resultados de E3	103
4.19. Identificación de los bordes de las líneas de cultivo en E1 , E2 y E3 . .	105
4.20. Ejemplo de los 3 tipos de operación efectuados por F1	106
4.21. Resultados de F1	108
4.22. Extracción de regiones en el método F2	109
4.23. Resultados de F2	110
4.24. Regiones fraccionadas	111
4.25. Resultados de F3	112
4.26. Plataforma de procesamiento de imágenes	114
4.27. Método de interpolación (<i>kriging</i>)	116
4.28. Estructura de un AG	120
4.29. Codificación para la combinación de métodos S1-E1-F2	122

ÍNDICE DE FIGURAS

4.30. Codificación para la combinación de métodos S2-E3-F1	122
4.31. Selección estocástica uniforme	125
4.32. Cruce disperso	125
4.33. Mutación gaussiana	125
4.34. Principales objetivos de una optimización multi-objetivo	133
4.35. Frentes de no-dominancia	134
4.36. Ordenación según nivel de no-dominancia implementada en <i>NSGA-II</i> .	136
4.37. Cálculo de la distancia de crowding	137
4.38. Estructura de <i>NSGA-II</i>	138
4.39. Codificación de los individuos al usar <i>NSGA-II</i>	139
4.40. Resultados del ajuste mediante <i>NSGA-II</i>	140
4.41. El ciclo CBR	146
4.42. Arquitectura del sistema CBR propuesto	149
4.43. Clases de pertenencia	151
4.44. Cálculo del atributo <i>Iluminación</i>	152
4.45. Cálculo del atributo <i>Estado crecimiento</i>	153
4.46. Cálculo del atributo <i>Error de sembrado</i>	154
4.47. Cálculo del atributo <i>Zona infestada</i>	155
4.48. Comparación de los mapas de cobertura de malas hierbas y biomasa . .	162
5.1. Método de toma de las imágenes en tiempo real en maíz	166
5.2. Perspectiva resultante en las imágenes	167
5.3. Ejemplo de frames	169
5.4. Procesamiento propuesto para tiempo real	171
5.5. Comparación de los métodos de umbralización	173
5.6. Variación del umbral durante el procesamiento	174
5.7. Segmentación de un frame	175
5.8. Resultados de PPF	177
5.9. Comparación de resultados de PT con distinto número de franjas . . .	179
5.10. Resultados de PT	180
5.11. Discriminación final entre cultivo y malas hierbas	180
5.12. Resultados del sistema ante situaciones variables	182
5.13. Mala hierba en cultivo de caña de azúcar	184
5.14. Método de toma de las imágenes en tiempo real en caña de azúcar . . .	185

5.15. Ejemplo de frames	187
5.16. Segmentación usando S1	189
5.17. Espectro de reflectancia del azúcar y malas hierbas	189
5.18. Discriminación por diferencias en las intensidades del azul	191
5.19. Discriminación por diferencias en la proporción de rojos y azules	193
5.20. Método de toma de las imágenes en tiempo real en caña de azúcar de noche	196
5.21. Iluminación usando dos bombillas Solux 50w	196
5.22. Iluminación usando dos leds Luxeon K2	197
5.23. Diferencias en color entre malas hierbas y azúcar	201
5.24. Diferencias en color entre malas hierbas y azúcar dependiendo de la iluminación	202
5.25. GUI para el ajuste de los parámetros del procesamiento	203
6.1. Volumen de aplicación según estado del cultivo	207
6.2. Tipos de equipos de tratamiento	208
6.3. Tipos de boquillas	209
6.4. Altura de los brazos	210
6.5. Sistema autónomo para tratamiento de malas hierbas en tomate (Lee et al., 1999)	213
6.6. La barra HARDI NK	215
6.7. Partes de las que se compone la barra de tratamiento HARDI NK . . .	216
6.8. Depósito, distribuidor y enganche de la barra	216
6.9. Distribuidor de producto de la barra	217
6.10. Sentido de giro de los seis motores de la barra	217
6.11. Enganche de la barra de tratamientos al motor	218
6.12. Cada una de las secciones de la barra contiene 5 boquillas en chorro de abanico	219
6.13. Diagrama del controlador 2500 incluido en la barra	219
6.14. Caja de control de la barra HARDI NK y sus funciones principales . . .	220
6.15. Esquema del sistema de control	221
6.16. Esquema del circuito de control diseñado	222
6.17. Esquema del puente LMD18200	223
6.18. Tarjeta de adquisición de datos Labjack U12	224

ÍNDICE DE FIGURAS

6.19. CPLD	225
6.20. Placas del circuito final	227
6.21. Alimentación de la barra usando un motor eléctrico	228
6.22. GUI para controlar la barra	228
6.23. Entradas y salidas del controlador	230
6.24. Funciones de pertenencia clásica y borrosa	232
6.25. Operaciones básicas entre conjuntos borrosos	234
6.26. Funciones de pertenencia de los conjuntos borrosos de entrada	236
6.27. Funciones de pertenencia de los conjuntos borrosos de salida	237
6.28. Decodificación de la salida a valores no borrosos mediante cálculo de centroide	241
6.29. Simulación del resultado del controlador borroso	242
6.30. Evolución de la acción de control sobre la velocidad y el caudal	243
6.31. Resolución de los muestreos discretos llevados a cabo	244
6.32. Resultados del controlador borroso sobre el muestreo del año 2007	245
6.33. Resultados del controlador borroso sobre el muestreo del año 2008	246
6.34. Resultados del controlador borroso sobre el muestreo del año 2009	246
6.35. Valores medios de cobertura de malas hierbas	248
6.36. Receptor GPS usado	249
6.37. Tratamiento selectivo a partir de mapa de tratamiento	250
7.1. VarioSelect	263

Índice de tablas

2.1. Precisión requerida en la localización según la operación a realizar . . .	18
4.1. Funcionamiento del método E3	102
4.2. Resultados del ajuste mediante algoritmo genético	128
4.3. Tiempo medio por imagen empleado para cada combinación de métodos	129
4.4. Complejidad computacional y tiempo medio empleado por cada método	130
4.5. Resultados del ajuste mediante <i>NSGA-II</i>	141
4.6. Ventajas e inconvenientes de cada método de procesamiento	143
4.7. Cálculo del atributo <i>Error de sembrado</i>	152
4.8. Descripción de las distintas configuraciones del sistema evaluadas	159
4.9. Pautas seguidas por Pseudo-CBR	160
4.10. Resultados del estudio comparativo de la plataforma con y sin CBR . .	160
5.1. Resultados del procesamiento	194
5.2. Resultados del procesamiento nocturno	197
5.3. Problema del procesamiento	199
6.1. Características de los distintos tamaños de gota	210
6.2. Reglas expertas para determinar la cantidad de herbicida a aplicar . . .	238
6.3. Ajuste de la salida actuando sobre el caudal y la velocidad	239

Índice de abreviaturas

AG	Algoritmos Genéticos
AP	Agricultura de Precisión
APS	Active Pixel Sensor
ASD	Dispositivo Espectral Analítico
BPA	Buenas Prácticas Agrarias
CBR	Razonamiento Basado en Casos
CCD	Charge Coupled Device
CCMA	Centro de Ciencias Medioambientales
CE	Comisión Europea
CMOS	Complementary Metal Oxide Semiconductor
CMYK	Cian;Magenta;Yellow;Black
CPLD	Circuito Lógico Programable Complejo
CPU	Unidad Central de Procesamiento
CSIC	Consejo Superior de Investigaciones Científicas
DAQ	Adquisición de datos
DGPS	GPS con capacidad de corrección Diferencial
EC	Estado de Crecimiento del cultivo

ÍNDICE DE ABREVIATURAS

FAO	Organización de las Naciones Unidas para la Agricultura y la Alimentación
FPS	Frames Por Segundo
GPS	Global Positioning System
GPU	Unidad de Procesamiento Gráfico
GUI	Interfaz Gráfica de Usuario
HM	Hot Mirror
HSI	Hue;Saturation;Intensity
IA	Inteligencia Artificial
IAI	Instituto de Automática Industrial
IC	Índice de Cobertura de malas hierbas
KDD	Descubrimiento de Conocimiento en Bases de Datos
MOEA	Algoritmo Evolutivo Multi Objetivo
Mp	Mega píxeles o Millones de píxeles
NCEA	National Centre for Engineering in Agriculture
NIR	Infrarrojo cercano
NSGA-II	Non-dominated Sorting Genetic Algorithm II
OMS	Organización Mundial de la Salud
ONU	Organización de las Naciones Unidas
PAC	Política Agrícola Común
RGB	Red;Green;Blue
SDSS	Sistemas de Ayuda a la toma de Decisiones Espaciales
SIG/GIS	Sistemas de Información Geográfica

SSD	Sistemas de Soporte a la Decisión
TAD	Tipo Abstracto de Datos
UE	Unión Europea
USB	Universal Serial Bus
USQ	University of Southern Queensland
VA	Visión Artificial

Capítulo 1

Introducción

El principio es la mitad del todo

Pitágoras

1.1. Aplicación selectiva de tratamientos

Tradicionalmente, las prácticas de cultivo se han orientado hacia una gestión uniforme del campo, ignorando la variabilidad tanto espacial como temporal que aparece. Esto presenta fundamentalmente dos tipos de inconvenientes: a) contaminación de la atmósfera y del suelo, con la consecuente contaminación de las aguas subterráneas ¹ y b) un notable aumento en el coste económico de la producción agrícola.

A lo anterior hay que añadir que en los próximos 25 años, debido al crecimiento económico global y al aumento de población en nuestro planeta, será necesario doblar

¹Según informes de la Organización Mundial de la Salud (OMS, 1992), los niveles de nitrógeno en el agua subterránea han aumentado en muchas partes del mundo como consecuencia de la “intensificación de las prácticas agrícolas”

la producción agrícola, disponiendo para ello cada vez de menos tierra y agua, lo que producirá grandes costes sociales, económicos y medioambientales. En consecuencia, será crucial la generación de herramientas que permitan minimizar los costes de producción a la vez que se realiza una gestión agrícola respetuosa con el medio ambiente (Srinivasan, 2006; Stafford, 2000).

En los últimos años, gracias al desarrollo de tecnologías como los Sistemas de Posicionamiento Global por satélite (GPS), sensores de cosecha, sensores de humedad o de fertilidad del suelo, sensores multiespectrales, sistemas de teledetección, Sistemas de Información Geográfica (SIG/GIS) y Sistemas de Soporte a la Decisión (SSD), ha surgido el concepto de **Agricultura de Precisión (AP)**, que engloba un conjunto de técnicas de cultivo dirigidas a ajustar el uso de agroquímicos considerando la diversidad tanto del medio físico como biológico (Kropff et al., 1997).

Dentro de la AP tienen especial importancia las técnicas orientadas a la aplicación selectiva de tratamientos, que en contraposición a los métodos agrícolas tradicionales, proponen ajustar las dosis de tratamientos a las necesidades de cada unidad de terreno, ya que cada campo de cultivo puede variar enormemente tanto en términos de composición de flora arvense como en su abundancia. En pocas palabras, se trata de aplicar herbicidas sólo en aquellas zonas en las que se encuentren malas hierbas, variando además la cantidad de tratamiento aplicado según la densidad de éstas. Numerosos estudios experimentales demuestran que es posible reducir substancialmente las dosis recomendadas de muchos productos sin que con ello se reduzcan significativamente ni su eficacia ni los rendimientos, lo que conduce a una reducción de los costes de producción y una gestión agrícola más precisa y respetuosa con el medio ambiente (Earl et al., 1996).

Para llevar a cabo una aplicación selectiva de tratamientos, el primer paso es la recogida de información en el campo que permita conocer la distribución de las malas hierbas y la variabilidad espacial de cada especie (etapa de Percepción), necesarias para calcular las necesidades, en términos de herbicida, de cada unidad de terreno (Senay et al., 1998). Una vez recogida dicha información, y conocidas por lo tanto las necesidades de cada unidad de terreno, el segundo paso es la planificación y realización de la aplicación selectiva de tratamientos en el campo (etapa de Actuación).

1.2. Motivación y objetivos

1.2.1. Motivación

El trabajo de investigación asociado a esta tesis se integra dentro de dos proyectos del plan nacional financiados por el Ministerio de Educación y Ciencia:

- “Extracción de conocimiento espacio-temporal y visión artificial para la automatización de tratamientos agrícolas localizados” (ECOVAAP, PLAN NACIONAL-AGL2005-06180-C03-03), desde enero de 2006 hasta diciembre de 2008.
- “Percepción visual, toma de decisión y actuación en sistemas artificiales complejos: Control selectivo de malas hierbas en cultivos agrícolas” (PERICIA, PLAN NACIONAL-AGL2008-04670-C03-02/AGR), desde enero de 2009 hasta diciembre de 2011.

Los objetivos de ambos proyectos se orientan al desarrollo de nuevas técnicas de percepción y detección de malas hierbas, así como de herramientas de automatización y control de los elementos de actuación, para lograr la aplicación selectiva de tratamientos.

La investigación de ambos proyectos se lleva a cabo en el Instituto de Automática Industrial (IAI) perteneciente al Consejo Superior de Investigaciones Científicas (CSIC), bajo la dirección de la Dra Ángela Ribeiro Seijas. Además, existe un contrato de colaboración con la Universidad Complutense, cuyo investigador responsable es el Profesor Gonzalo Pajares Martinsanz.

Los tipos de cultivo escogidos para el desarrollo de la investigación son el cereal de invierno y el maíz, primer y cuarto cultivo de mayor peso en la producción agrícola española con 19,5 y 3,6 millones de toneladas anuales respectivamente. Asimismo, son los dos granos más producidos a nivel mundial (FAO, 2007).

Estos cultivos se sitúan además entre aquellos con mayores necesidades de superficie para su producción, dedicándose actualmente en España 56 millones de hectáreas para cereales y 3,6 millones de hectáreas para maíz, por lo que el impacto de una aplicación uniforme de agroquímicos es enorme, justificando claramente la necesidad del desarrollo de técnicas y maquinaria para la aplicación de tratamientos selectivos.

Todas las pruebas de campo se han realizado en la finca de La Poveda (Madrid), por parte de personal tanto del IAI-CSIC (incluido el propio doctorando) y del Centro de Ciencias Medioambientales (CCMA-CSIC), al cual pertenece la finca.

Además, gracias a la financiación ofrecida para estancias en el extranjero por la beca predoctoral de formación de personal investigador del programa I3P del CSIC de la que disfruta el doctorando, la investigación pudo ser ampliada a campos de caña de azúcar. El trabajo que se presenta corresponde a una estancia de 5 meses en el National Centre for Engineering in Agriculture (NCEA), de la Universidad de Southern Queensland (USQ), Australia.

La caña de azúcar es el cultivo más importante en Australia, produciéndose más de 36 millones de toneladas anuales. La situación geográfica de la mayoría de los campos de azúcar (en la costa adyacente al arrecife de coral, principal fuente de turismo del país y declarado patrimonio de la humanidad por la Unesco) ha obligado al gobierno australiano a imponer restricciones muy severas sobre el uso de fitosanitarios. Esto ha llevado a que las mayores empresas azucareras del país contraten el desarrollo de técnicas e instrumentación para realizar una gestión selectiva de las infestaciones en estos cultivos.

El proyecto del NCEA “A Coordinated Approach to Precision Agriculture RDE for the Australian Sugar Industry”, es un contrato con la mayor empresa azucarera del país *Sugar Research & Development Corporation Bundaberg Sugar Ltd.* Todas las pruebas en campo se han realizado en campos de caña de azúcar propiedad de la empresa en Bundaberg, Australia, por personal del NCEA (incluido el propio doctorando).

1.2.2. Objetivos

El objetivo principal del presente trabajo de investigación es el desarrollo tanto de los mecanismos de percepción para la detección automática de infestación como de los métodos de toma de decisión y actuación que den lugar a una exitosa aplicación selectiva de tratamientos.

1. Percepción

1.1 Experimentación de toma de imágenes de malas hierbas, cultivo y suelo

1.2. Motivación y objetivos

de forma manual o automática usando cámaras convencionales.

1.2 Estudio de las características discriminantes de las malas hierbas frente al cultivo. Extracción de conocimiento experto para la correcta localización, etiquetado y estimación de la densidad de ambos.

1.3 Análisis y descripción de las diferentes condiciones de trabajo a las cuales hay que enfrentarse: variabilidad espacial y temporal de la infestación, distintas situaciones meteorológicas y de iluminación, estados de crecimiento, etc.

1.4 Desarrollo de métodos automáticos de procesamiento de imágenes para la correcta extracción y discriminación de cultivo y malas hierbas bajo una gran diversidad de condiciones posibles de trabajo.

1.5 Prueba y optimización de los métodos desarrollados sobre imágenes tomadas en el campo. Muestreo discreto de malas hierbas.

1.6 Desarrollo de métodos automáticos para la detección en tiempo real de malas hierbas, a partir de vídeos adquiridos por una cámara colocada directamente sobre el tractor.

2. Actuación

2.1 Automatización de una barra de aplicación de tratamientos. Control sobre la apertura/cierre y caudal de cada uno de los sectores de la barra desde un ordenador usando una tarjeta de adquisición de datos y la electrónica necesaria.

2.2 Desarrollo de un controlador sobre los módulos de actuación que aplique la dosis óptima de herbicida en función de la información recogida en la etapa de percepción, dando lugar a la aplicación de tratamientos selectivos.

1.2.3. Principales hitos a alcanzar

- Disponer de métodos automáticos de percepción capaces de extraer correctamente los elementos naturales presentes en una imagen. Dichos métodos pueden posteriormente usarse para elaborar mapas de cobertura de malas hierbas, cultivos y suelo.

- Disponer de un sistema de adquisición y procesado de imagen para detección de elementos naturales en tiempo real.
- Disponer de un sistema de control sobre la barra de aplicación de tratamientos que permita manejar de forma independiente cada sección de la barra y ajustar la cantidad de herbicida aplicada.
- Integrar los métodos de percepción y actuación en un único sistema de aplicación de tratamientos selectivos.
- Usar un equipo lo más barato y sencillo posible, facilitando de este modo su posible uso por parte de un agricultor, con vistas a que la investigación desarrollada tenga una aplicación real.

1.3. Estructura de la tesis

Esta memoria se divide en 3 partes distintas, cada una separada a su vez en capítulos.

- PARTE I: Estado del arte

Capítulo 2: En este capítulo se discute la repercusión de la agricultura sobre la sociedad y el medioambiente, introduciendo el concepto de Agricultura de Precisión(AP) y presentando las técnicas de tratamiento selectivo de malas hierbas. Asimismo, se estudian los requisitos y pasos a seguir para diseñar e implementar dichas técnicas, y se repasan los trabajos desarrollados hasta el momento.

Capítulo 3: En este capítulo se introduce el concepto de Visión Artificial (VA), explicando brevemente sus aspectos y aplicaciones más relevantes en relación al trabajo desarrollado. Se hace hincapié en su aplicación en diversas áreas de la agricultura. Por último, se revisan trabajos de VA aplicados a la extracción de elementos naturales.

- PARTE II: Sistema autónomo de aplicación de herbicida

Capítulo 4: En este capítulo se presentan los métodos de percepción desarrollados para efectuar una detección automática de malas hierbas, cultivo y suelo

partiendo de un muestreo fotográfico discreto. El procesamiento de las imágenes se divide en tres etapas. Para cada una de ellas se han diseñado varios métodos, permitiendo un procesamiento robusto ante todas las distintas situaciones encontradas de iluminación, estados de crecimiento del cultivo, densidad de la infestación, etc. Dichos métodos han sido posteriormente optimizados mediante algoritmos genéticos sobre un conjunto grande de imágenes de cultivos de cereal. Todos los métodos han sido incluidos en una plataforma de procesamiento de imágenes desarrollada en C++, a la cual se dotó de un sistema de razonamiento basado en casos, que ajusta el procesamiento en función de las características de cada imagen de entrada.

Capítulo 5: En este capítulo se presentan los métodos de percepción desarrollados para la extracción de elementos naturales en tiempo real a partir de vídeos adquiridos por una cámara colocada directamente sobre el tractor. Los métodos hacen frente a tremendas limitaciones en tiempo de cómputo y a la toma de imágenes inestable, producida por el traqueteo del tractor y a las irregularidades del terreno. La primera parte del capítulo presenta los métodos sobre campos de maíz, mientras que la segunda parte del capítulo presenta los métodos sobre caña de azúcar.

Capítulo 6: En este capítulo se introducen los distintos equipos de tratamiento existentes y técnicas de pulverización de herbicidas. Posteriormente, se explica cómo se ha llevado a cabo la automatización de una barra de tratamientos de forma que se pueda controlar a través de un ordenador. Una vez efectuada la automatización, se estudia el diseño y desarrollo de un controlador multivariable para ajustar los tratamientos en respuesta a la información recogida en la etapa de percepción.

- PARTE III: Conclusiones y trabajo futuro

Capítulo 7: En este capítulo se resumen las principales aportaciones de este trabajo, se discuten los resultados obtenidos, y se estudian las líneas de investigación futura. Por último, se detallan las publicaciones y patentes industriales a las que ha dado lugar este trabajo y se mencionan brevemente alguno de los proyectos paralelos asociados.

Parte I

Estado del arte

Capítulo 2

Agricultura de Precisión

Parte cayó en pedregales, donde no había mucha tierra; y brotó pronto, porque no tenía profundidad de tierra; pero salido el sol, se quemó; y porque no tenía raíz, se secó. Y parte cayó entre espinos; y los espinos crecieron, y la ahogaron. Pero parte cayó en buena tierra, y dio fruto, cuál a ciento, cuál a sesenta, y cuál a treinta por uno

San Mateo 13:5-8

2.1. El papel de la agricultura en la sociedad y el medio ambiente

La agricultura, *el arte de cultivar la tierra*, fue el factor fundamental que llevó a la fundación de la civilización moderna, dando la posibilidad de alimento a un mayor número de individuos y permitiendo el desarrollo de una sociedad sedentaria, más

compleja, en la que aparecieron actividades comerciales y de transporte, y donde el concepto de propiedad de tierras dio incluso origen a los primeros sistemas jurídicos y gubernamentales.

En el 2007, la agricultura seguía dando trabajo al 34,9 % de la población mundial, habiendo sido hasta el año 2003 la mayor fuente de empleo, cuando fue reemplazada por primera vez por el sector de servicios, como se muestra en la figura 2.1 (ILO, 2008).




Figura 2.1: Evolución del empleo mundial por sectores, 1997 hasta 2007 (ILO, 2008)

Esta disminución en el número de trabajadores en el campo se debe principalmente a la mecanización agraria, considerada uno de los mayores logros de la ingeniería del siglo pasado. A principios del siglo XX, según la Academia Internacional de Ingeniería de EE.UU, era necesario un granjero para alimentar de 2 a 5 personas, mientras que en la actualidad, gracias principalmente a la tecnología y a los agroquímicos, un granjero alimenta a unas 130 personas.

Sin embargo, la agricultura es una actividad cuyo alcance va más allá de la simple producción de alimentos. La mecanización agraria y la intensificación de la agricultura traen consigo un tremendo impacto sobre el medio ambiente. En la Unión Europea

2.1. *El papel de la agricultura en la sociedad y el medio ambiente*

(UE), sin ir más lejos, más de la mitad de la superficie terrestre se usa para la agricultura, lo que pone claramente de manifiesto la importancia que reviste la actividad agraria para el medio ambiente.

El impacto medioambiental de la agricultura no es una cuestión aislada, sino que está claramente relacionada con cuestiones que afectan a todo el planeta como son el cambio climático, la contaminación procedente de nitratos y plaguicidas, la protección del suelo, la gestión del agua y la conservación de la biodiversidad. En la hoja informativa distribuida por la Dirección General de Agricultura de la UE (CE, 2003), se enumeran muchos de los problemas actuales de la agricultura, como por ejemplo:

- Generación de gases de efecto invernadero, siendo sus mayores fuentes el óxido nitroso (N_2O) por emisiones procedentes de abonos nitrogenados y la gestión de estiércol, y el metano (CH_4), el 41 % del total de emisiones en la UE siendo procedentes de la agricultura.
- Contaminación de la atmósfera y el suelo por el uso en exceso de plaguicidas (insecticidas, herbicidas, fungicidas, etc.).
- Degradación del suelo (desertización, erosión, disminución de materia orgánica, contaminación, sellado, compactación, pérdida de biodiversidad, salinización). Tales procesos de degradación pueden ser el resultado de prácticas agrarias inadecuadas, como fertilización desequilibrada, captación excesiva de aguas subterráneas para regadío, uso incorrecto de plaguicidas o utilización de maquinaria pesada.
- Gestión inadecuada del agua. El sector de la agricultura es un importante usuario de recursos hídricos en Europa, con aproximadamente el 30 % del total del consumo de agua. En numerosos países del sur, como España, (donde es un factor de producción fundamental) el regadío supone más de 60 % del uso total de agua.
- Impacto sobre la biodiversidad. En los últimos decenios se ha acelerado en todo el mundo la desaparición de especies, así como el declive de los hábitats, ecosistemas y riqueza genética relacionada con ellos.

Además, se calcula que en los próximos 25 años, a consecuencia del crecimiento económico global y del aumento de la población de nuestro planeta, será necesario doblar la producción agrícola, disponiendo para ello cada vez de menos espacio, agua y

demás recursos naturales. En consecuencia, es imperativa la aplicación de una agricultura más sostenible económicamente, socialmente y ecológicamente (Bongiovanni y Lowenberg-Deboer, 2004).

En Europa, las políticas de la UE y en particular la *Política Agrícola Común (PAC)*, se orientan cada vez más a fomentar la creación e implementación de técnicas agrícolas más sostenibles. La propia página de la Dirección General de Agricultura de la UE (CE, 2009a,b) dice textualmente:

La PAC debería centrarse en las siguientes prioridades:

- *Proporcionar alimentos sanos y seguros.*
- *Asegurar a los agricultores un nivel de vida digno.*
- *Fomentar el respeto del medio ambiente.*
- *Garantizar el bienestar de los animales.*
- *Ayudar a los agricultores a adaptarse a las expectativas de los consumidores.*
- *Asegurar precios razonables para los consumidores.*
- *Estimular el crecimiento y el empleo en las zonas rurales.*

El objetivo principal de la PAC es fomentar la calidad, la seguridad, un sector agrario en armonía con el medio ambiente y el bienestar de los animales. En definitiva y de cara al futuro, es preciso desarrollar aún más la sostenibilidad del sector agroalimentario europeo.

En otras palabras, uno de los objetivos principales de la UE es alcanzar una agricultura competitiva, orientada al mercado, que mejore las condiciones de vida y las oportunidades de trabajo en las zonas rurales, y que respete las buenas prácticas medioambientales, la biodiversidad y el paisaje.

Para todo esto, en la reforma de la PAC de la Agenda 2000 se introdujo el concepto de *buenas prácticas agrarias (BPA)*, que definen el nivel a partir del cual el agricultor puede incorporarse a los planes agroambientales. Es decir, sólo las prácticas agrarias que incluyan BPA podrán optar a los pagos agroambientales que compensan las pérdidas de renta que sufren los agricultores al realizar una gestión del cultivo respetuosa con

el medio ambiente. El cumplimiento de normas ambientales mínimas es una condición necesaria para optar a diversas ayudas cuya finalidad es fomentar las inversiones en explotaciones agrarias, el establecimiento de jóvenes agricultores, la mejora del procesamiento y la comercialización de productos agrarios.

2.2. Agricultura de Precisión

Las prácticas en cultivos tradicionales se han orientado, en las grandes explotaciones, hacia una gestión uniforme del campo, ignorando la variabilidad espacial y temporal debido al alto coste que supone un tratamiento desigual. Es decir, todo el campo se trata del mismo modo todos los años, a pesar de que puede presentar necesidades distintas cada año según la zona.

En las últimas décadas, gracias al desarrollo de nuevas tecnologías, se ha producido un importante avance con la aplicación de sistemas de control y automatización en agricultura, apareciendo el concepto de **Agricultura de Precisión (AP)**, que engloba un conjunto de técnicas de cultivo dirigidas a ajustar el uso de agroquímicos considerando la diversidad tanto del medio físico como biológico (Kropff et al., 1997). Estudios experimentales realizados sobre cultivos de cereal en Alemania (Gerhards, 2007), España (Ruiz et al., 2006) y la República Checa (Homouz, 2007) muestran ahorros por encima del 70 %, 74 % y 82 % respectivamente, demostrando que usando estas técnicas de precisión es posible reducir substancialmente las dosis recomendadas de muchos productos sin que con ello se reduzcan significativamente ni su eficacia ni los rendimientos en la cosecha, traducándose en una reducción de los costes de producción y una gestión agrícola más respetuosa con el medioambiente (Earl et al., 1996).

La AP, consiste básicamente en “*Hacer lo oportuno, de forma conveniente, en el lugar y momento adecuados*” (Pierce y Nowak, 1999). Puede definirse como una estrategia de gestión de campos de cultivo donde el agricultor varía las prácticas (siembra, aplicación de fertilizantes y tratamientos, poda, cosecha, etc.) según las condiciones encontradas de suelo, atmósfera, estado del cultivo y malas hierbas en las distintas zonas del campo.

Los beneficios a los que conduce la aplicación de la AP son los siguientes (Srinivasan, 2006):

1. **Reducción de los costes:** Al aplicar dosis variables de agua, fertilizantes y tratamientos según las necesidades de cada zona en lugar de aplicar siempre la dosis máxima, se produce una importante disminución en las cantidades usadas de todos estos productos, con el consecuente ahorro económico.
2. **Optimización del rendimiento y calidad de la cosecha en relación con la capacidad productiva de cada campo:** El tratar todo el campo por igual (prácticas agrícolas tradicionales), puede dar lugar a que algunas zonas reciban más o menos cantidad de un producto de lo que en realidad necesitan, empeorando el bienestar del cultivo. Con una gestión dependiente de las necesidades de cada zona, se suministra al cultivo justo lo que necesita, mejorando el rendimiento y la calidad del mismo.
3. **Mejor uso de los recursos naturales:** El ahorro en agua y demás productos mejora el uso de los recursos naturales disponibles.
4. **Protección del medioambiente:** El uso en exceso de algunos productos (agua, fertilizantes, plaguicidas, etc.) tiene un impacto importante sobre el medioambiente. Usar sólo y exclusivamente las cantidades necesarias de cada uno de ellos, reduce en gran medida los problemas medioambientales.
5. **Facilitar la tarea del agricultor:** Al ahorrar en muchos de los productos agroquímicos, el tiempo necesario para su aplicación es inferior, reduciéndose por lo tanto la carga de trabajo del agricultor, siempre que el proceso esté altamente automatizado.

Ahora bien, el uso de la AP no está indicado para cualquier situación. Para que sea razonable pensar qué técnicas de AP pueden mejorar una determinada producción agrícola, se deben cumplir mínimo tres requisitos:

1. La existencia de variabilidad espacial y temporal en el estado del suelo y las condiciones del cultivo dentro del campo a tratar.

2.2. Agricultura de Precisión

2. Que sea posible identificar y cuantificar dicha variabilidad de algún modo.
3. Que sea posible mejorar el rendimiento y la calidad de la cosecha haciendo uso de dicha variabilidad a la hora de planificar las operaciones requeridas en el campo.

La aplicación de una estrategia de AP puede verse como un ciclo de 3 etapas, figura 2.2. Primero, se recoge información sobre el campo de cultivo a tratar. Esa información se analiza e interpreta, dando lugar a un plan de actuación sobre las distintas etapas de la producción agrícola. La naturaleza de la información recogida depende en gran medida del tipo de gestión que se quiere llevar a cabo. Por ejemplo para elaborar un plan de sembrado se necesitará información sobre el estado del suelo, mientras que para saber dónde es necesario aplicar herbicida lo que se necesita es localizar con precisión las malas hierbas. Este es un ciclo de *Percepción-Interpretación/Toma de decisión-Actuación*, es decir, se observa el estado del campo, y se toman decisiones sobre cómo tratarlo en función de lo observado y del objetivo perseguido.

Otra forma de entender la AP es como un sistema de toma de decisiones que se apoya sobre el conocimiento existente (agronomía, malherbología, geología, etc.) para determinar la mejor gestión del campo en función de unos datos de entrada con información sobre el cultivo, figura 2.3 (Stafford, 2000).

Por lo tanto, la utilización de estrategias de AP, requiere métodos que permitan:

1. Localizar de modo preciso posiciones dentro del campo.
2. Recoger, interpretar y analizar la información obtenida con suficiente frecuencia.
3. Modificar fácilmente las actuaciones sobre el campo para maximizar el rendimiento y calidad de cada una de las zonas.

Es fundamental disponer de algún sistema de localización que permita asociar a cada elemento observado su posición real dentro del campo. La precisión necesaria en el posicionamiento dependerá de las operaciones a efectuar. En la tabla 2.1 se muestran, a modo de ejemplo, varias operaciones en las que la precisión requerida está entre 30m y 1cm (Srinivasan, 2006).

Tan importante es la localización, que aunque algunos trabajos pioneros (Johnson et al., 1983) asentaron ya las bases de la AP, las primeras aplicaciones no aparecieron hasta

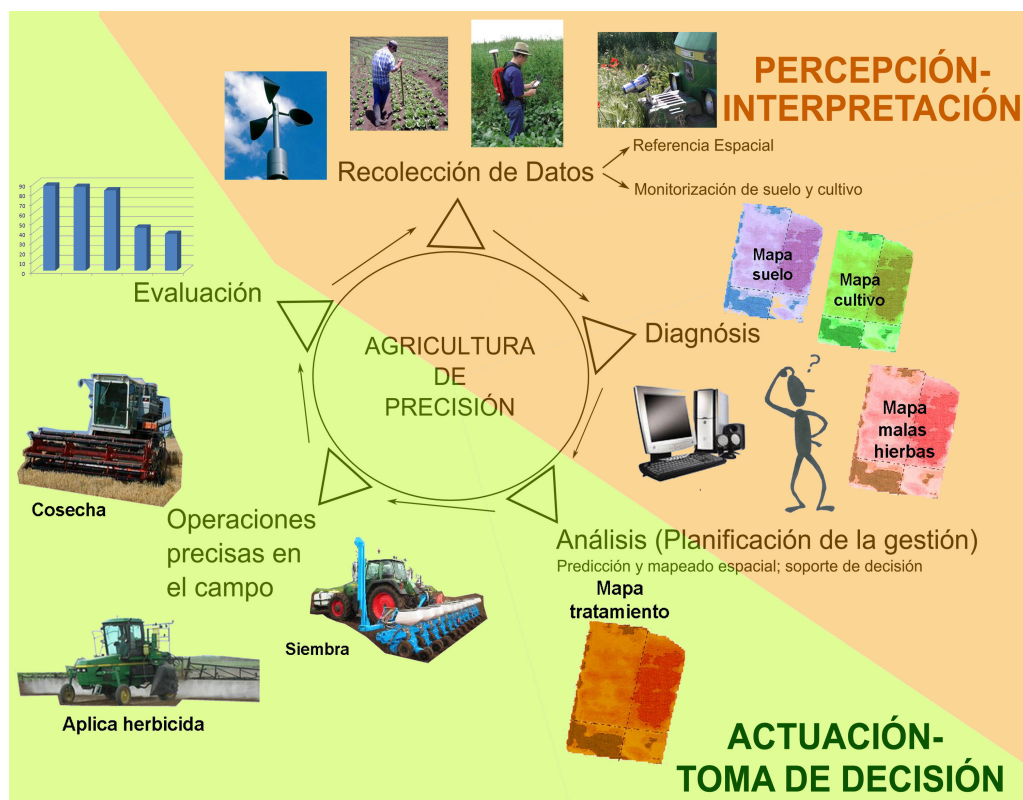


Figura 2.2: Ciclo de la Agricultura de Precisión

Operaciones a efectuar	Precisión requerida
Aplicación de fertilizante	30m
Mapas de rendimiento de la cosecha	10m
Aplicación variable de herbicida	1m
Siembra	50cm
Tratamiento de hoja	1cm

Tabla 2.1: Precisión requerida en la localización de elementos según la operación a realizar

2.2. Agricultura de Precisión

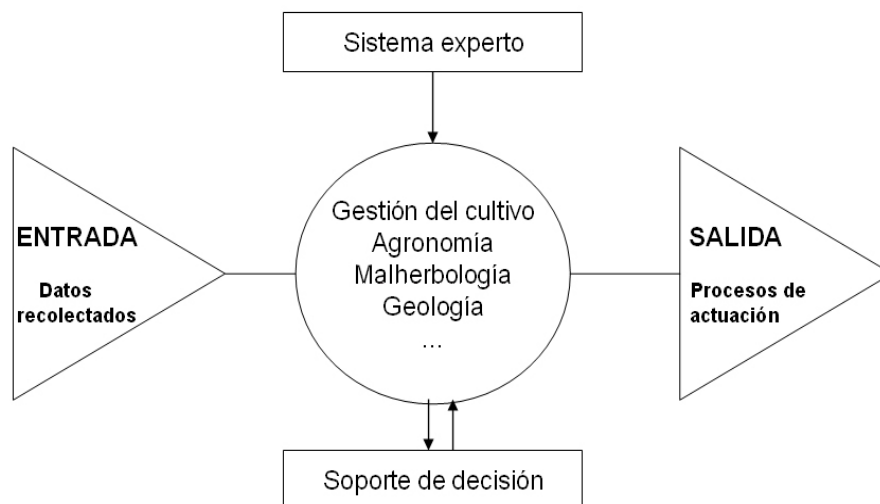


Figura 2.3: Diagrama de flujo de la aplicación de técnicas de Agricultura de Precisión

principios de la década de los 90 con la llegada del *Global Positioning System* (GPS), un sistema de posicionamiento mediante satélites desarrollado por el departamento de defensa de los EE.UU. en los años 70 y puesto a disposición de aplicaciones civiles en 1995.

El GPS utiliza una red de ordenadores y una constelación de 24 satélites para calcular, mediante técnicas de triangulación, la posición (altitud, longitud, latitud) de cualquier objeto en la superficie terrestre.

El sistema consta de tres partes o segmentos distintos:

- **Segmento espacio:** formado por la constelación de 24 satélites operativos con una órbita sobre el globo a 20.000 Km, con trayectorias sincronizadas para cubrir toda la superficie de la Tierra.
- **Segmento control:** formado por cinco estaciones monitoras encargadas de mantener en órbita los satélites y supervisar su funcionamiento, tres antenas terrestres que envían a los satélites las señales que deben transmitir y una estación que efectúa una supervisión global del sistema.

- **Segmento usuario:** formado por todas las antenas y receptores pasivos situados en la tierra.

La posición (x, y, z) de un objeto se calcula mediante triangulación a partir de las distancias entre el objeto y un mínimo de tres satélites. La distancia entre el receptor y cada uno de los satélites se puede hallar dados el tiempo de vuelo de la señal emitida desde el satélite y su velocidad de propagación (velocidad de la luz).

Para medir correctamente el tiempo de vuelo de la señal es imprescindible que los relojes de los satélites y el receptor estén sincronizados, y que la señal emitida por el satélite no se confunda con el resto de señales radio del planeta. Para ello, cada receptor GPS genera un código pseudoaleatorio artificial, usado como patrón por el satélite a la hora de emitir su señal. De este modo, el receptor puede calcular el tiempo de vuelo desplazando temporalmente su código pseudoaleatorio hasta que éste coincida con el emitido por el satélite. Mediante este procedimiento, la posición de cada satélite puede estimarse con un error inferior a varios metros, a pesar de su gran velocidad ($4Km/s$).

Los códigos pseudoaleatorios se componen de tres tipos de cadenas: código C/A (Coarse/ Acquisition) de uso civil, con frecuencia de 1023Mhz, código P con una frecuencia 10 veces superior al código C/A, de uso militar, y el código Y, también de uso militar, que se envía criptografiado para evitar que fuerzas hostiles generen y transmitan una señal igual a la de los satélites. Los satélites emiten las señales en dos frecuencias, L1 a 1575,42 Mhz y L2 a 1227,60 Mhz.

Dependiendo de la configuración utilizada, se distinguen dos niveles de servicio distintos: el servicio de posicionamiento estándar (SPS), que usa código C/A de frecuencia simple en la banda L1, y el servicio de posicionamiento preciso (PPS), basado en código P de frecuencia dual en la banda L2.

En aplicaciones que no requieren gran precisión se puede utilizar un receptor de único canal y bajo coste, que calcula la distancia con cuatro satélites en un intervalo de 2 a 30 segundos y precisión de 20 metros. Sin embargo, para una localización más precisa y rápida, se han desarrollado receptores de más canales, que además disminuyen el error de localización utilizando métodos de corrección diferencial (DGPS).

El movimiento del satélite durante el cómputo de la distancia, junto con el tiempo

2.2. Agricultura de Precisión

que se tarda en obtener las posiciones, el paso de las ondas por la ionosfera y la troposfera, los errores en el reloj del satélite, o errores en la información que envía el propio satélite, hacen que se produzca un error en la medida, existiendo una diferencia entre la posición calculada y la posición real del receptor.

Ahora bien, este error puede ser estimado en estaciones GPS terrestres fijas repartidas en sitios estratégicos que captan las señales de los satélites GPS. Como son estaciones fijas, es posible conocer las coordenadas geográficas y calcular el error en desplazamiento (latitud, longitud) y altura (altitud). Este error se transmite en un código predefinido (RTCM) y cualquier receptor con capacidad de corrección diferencial (DGPS) puede acceder a él para corregir su posición.

Entre los tipos de correcciones posibles las hay que permiten conseguir un gran número de localizaciones por segundo (alta frecuencia) con un error por debajo del centímetro. Éste es el caso de los receptores RTK (Real Time Kinematic) que reciben la corrección en fase a partir de la señal emitida por una estación base de la que se conoce la coordenada geográfica exacta. Otro tipo de correcciones permiten obtener localizaciones con errores por debajo del metro. En este caso, la corrección es en código y se puede recibir de distintos modos: a) por algún sistema de satélites, como por ejemplo Omnistar; b) por radio, a través de algún canal preparado para ello, como una emisora de FM; y c) descargada de Internet o con una conexión inalámbrica.

Hasta hace poco, estos servicios eran privados, siendo imprescindible pagar una cuota anual para acceder a ellos. Sin embargo, en el 2007 la Agencia Espacial Europea lanzó el European Geostationary Navigation Overlay Service (EGNOS), un servicio gratuito de corrección diferencial. Este servicio capta errores de medida a través de múltiples estaciones de referencia, creando un “mapa” corrector. La información se envía a una red de tres satélites geoestacionarios, los cuáles la envían a los receptores.

Durante los primeros años, los sistemas GPS no eran lo suficientemente rápidos ni fiables como para lograr localizar puntos dinámicos en un campo. Su precisión se situaba normalmente por encima de los 20 metros, y además se producían continuas pérdidas de señal por árboles o edificios (Lachapelle y Henriksen, 1995; Pozo-Ruz et al., 2000). Con la liberación de la señal y gracias a la corrección diferencial, el GPS ha alcanzado gran madurez. Dependiendo del receptor usado y del tipo de sistema contratado, en la actualidad este sistema proporciona posiciones con precisión por debajo del centímetro.

Aún así, debido a que sigue siendo una tecnología controlada por los militares, su potencial no puede desarrollarse totalmente para uso civil (muchas funciones están bloqueadas). Debido a ello, la UE pondrá en marcha un sistema alternativo, llamado *Galileo*, que debería empezar a funcionar en 2011 y mejorar los resultados del GPS, ofreciendo precisiones del orden de metros ya en su versión estándar (sin corrección diferencial). Entre las ventajas que ofrecerá el sistema Galileo están:

- Datos más exactos en las regiones cercanas a los polos (las órbitas de los satélites estarán ligeramente inclinadas hacia los polos).
- Disponibilidad continua del servicio y en situaciones extremas información a los usuarios, en segundos del fallo de un satélite. Esta forma de funcionamiento es crucial en aplicaciones como el control de tráfico aéreo o la conducción de automóviles.
- Diez bandas diferentes de frecuencia para suministrar de forma independiente señales supletorias de radionavegación, lo que hará que el sistema sea robusto frente a interferencias accidentales, fallos de los satélites, degradación de la señal, etc.

Aunque el GPS fue, sin duda alguna, el desencadenante que permitió imaginar que otro tipo de agricultura era posible (Pierce y Nowak, 1999), ha sido necesario avanzar en las áreas de electrónica, comunicaciones e informática, así como incorporar mejoras en maquinaria agrícola para situarnos tecnológicamente en una posición que permite vislumbrar a corto-medio plazo una incorporación real de las técnicas de AP en las prácticas agrícolas habituales. Todo esto se puede resumir en los siguientes puntos:

- Sin las capacidades de cómputo y almacenamiento de los ordenadores de la última década, nunca se habría podido crear, almacenar, organizar, manipular e interpretar toda la información que la AP maneja. De especial importancia son en este aspecto los *Sistemas de Información Geográfica* (SIG), que pueden definirse como una integración organizada de herramientas hardware, software y datos geográficos diseñados para capturar, almacenar, manipular, analizar y desplegar en todas sus formas la información geográficamente referenciada. Los SIG, junto

2.2. Agricultura de Precisión

con los *Sistemas de Soporte a la Decisión* (SSD) forman *Sistemas de Ayuda a la toma de Decisiones Espaciales* (SDSS). Estos últimos sistemas permiten almacenar y razonar sobre datos con localización espacial y, en algunos casos, también permiten el razonamiento temporal.

- De no ser por la aparición de sensores de cosecha, humedad, fertilidad del suelo, multiespectrales o sistemas de teledetección, nunca habría podido recogerse toda la información necesaria a cualquier proceso de AP. El problema, en muchos casos, es cómo extraer información útil de esta gran cantidad de datos. Algunos trabajos proponen y utilizan técnicas de Descubrimiento de Conocimiento en Bases de Datos (KDD) (Díaz et al., 2005; Ribeiro et al., 2003).
- Sin los tractores, cosechadoras, sembradoras, abonadoras y equipos de tratamiento modernos, no se podrían llevar a cabo las operaciones precisas en el campo.

La lista de posibles aplicaciones de la AP es larga y variada, resumiéndose en los siguientes grandes bloques:

- Monitorización del estado del suelo
- Monitorización de los elementos naturales del campo (cultivo, malas hierbas, insectos, plagas)
- Siembra/Cultivo variable
- Aplicación variable de agua
- Aplicación variable de fertilizantes
- Aplicación variable de tratamientos (herbicidas y plaguicidas)
- Monitorización y elaboración del mapa de rendimiento de la cosecha
- Monitorización y elaboración del mapa de calidad de la cosecha

En la actualidad las aplicaciones de la AP más frecuentes son la monitorización del rendimiento y la calidad de la cosecha, seguidas por la monitorización del estado del suelo y aplicación variable de fertilizantes (Lowenger-DeBoer, 2003). No obstante, la

aplicación de técnicas de AP no está todavía integrada en la gestión agrícola y mucho menos extendida.

La inmensa mayoría de las aplicaciones reales de la AP tienen lugar en los países más ricos (Europa, EE.UU., Canada, Australia), e incluso aquí se estima que se utiliza en menos del 5 % de las producciones agrícolas. La reticencia por parte de los agricultores a adoptar estas medidas se debe principalmente a lo difícil que resulta utilizar, sin formación específica, toda la tecnología asociada, y al elevado coste que cuestiona, en muchas ocasiones, el rendimiento económico de la AP. Otro cuello de botella importante es la falta de métodos de toma de decisión; nadie sabe a ciencia cierta cómo debe variar la actuación sobre el campo en función de los datos recogidos de estado de suelo, cultivo, etc.

A pesar de estos problemas, la imperiosa necesidad de implementar una agricultura más sostenible, está cambiando muchas de las agendas políticas en varios países, fomentando la investigación en el área y proponiendo ayudas económicas a los agricultores que usen estos sistemas, por lo que se espera que en la próxima década la gestión agrícola con métodos de AP se encuentre bien establecida, al menos en Europa, EE.UU., Canada y Australia.

2.3. Tratamiento selectivo de malas hierbas

El tratamiento de las malas hierbas es algo necesario en la gestión de toda producción agrícola. Las malas hierbas compiten con el cultivo por el espacio, el agua, los nutrientes y la luz, pudiendo tener un impacto importante sobre el rendimiento y la calidad de la producción. Esto se ha demostrado varias veces en muchos estudios, aunque las cifras observadas varían mucho dependiendo del tipo de cultivo, las especies de las malas hierbas consideradas y las condiciones de los experimentos. Por ejemplo, en Monaco et al. (1981) se observaron pérdidas de entre el 48 % y el 71 % en cultivos de tomate debidas a la aparición de *Datura stramonium*, *Ipomoea*, *Xanthium strumarium*, y *Digitaria sanguinalis*. En Keeley y Thullen (1991), las pérdidas observadas en algodón, debido a infestaciones de *Sorghum halepense* y *Echinochloa crus-galli*, estaban entre el 60 % y el 69 %. Por último, en Hodgson (1968) las pérdidas en cereal se situaban en torno al 15 % a consecuencia de la infestación de *Cirsium arvense*. En algunos casos

2.3. *Tratamiento selectivo de malas hierbas*

la mala hierba puede incluso acabar con el 100 % cultivo, como observó Roberts et al. (1977) en campos de lechuga.

La eliminación de las malas hierbas puede llevarse a cabo de varios modos. Arrancadas (a mano o mediante el uso de algún brazo mecánico) (Astrand y Baerveldt, 2002), quemadas, electrocutadas (Blasco et al., 2002) o tratadas mediante herbicidas, método más fácil de llevar a cabo y eficaz en la mayoría de los casos.

Los productos fitosanitarios, se utilizan frecuentemente por las ventajas económicas que reportan, al combatir las infestaciones que afectan a los cultivos y reducir la competencia de las malas hierbas, mejorando las cosechas y protegiendo la calidad, fiabilidad y precio final del producto cosechado. Sin embargo, el suelo, la atmósfera y el agua pueden quedar contaminados como resultado de prácticas de aspersión, dispersión de fitosanitarios en el suelo, limpieza de material o vertidos incontrolados (CE, 2009b). Estudios recientes muestran que el 95 % de estos productos de tratamiento alcanzan destinos distintos del original, como el aire, las aguas y los sedimentos subterráneos e incluso la comida (Miller, 2004). La salud humana y animal pueden verse perjudicadas por exposición directa (por ejemplo, los trabajadores de la industria que fabrican productos fitosanitarios y los operarios que los aplican) o indirecta (por ejemplo, a través de los residuos que dejan en las cosechas y en el agua potable, o por la exposición que sufren personas o animales que se encuentran fortuitamente en la zona en el momento del tratamiento), (CE, 2003). En el 2001, se usaron más de 2,6 millones de toneladas de fitosanitarios en el mundo, más de la mitad en la UE (FAO, 2007). Según informes de la Organización Mundial de la Salud (EHH, 2003; OMS, 1992), se estima que anualmente se producen tres millones de casos de envenenamiento por estos productos, causando 220.000 muertes, además de considerarse como responsables de una alta variedad de cánceres infantiles por ingestión de residuos en alimentos.

Por ello, dentro de la AP, tienen especial importancia las técnicas orientadas a la aplicación selectiva de tratamientos, que proponen ajustar las dosis de fitosanitarios a las necesidades de cada unidad de terreno, en contraposición con las técnicas tradicionales que aplicaban la dosis máxima sobre todo el campo. Estas técnicas son ahora más que nunca un objetivo global en muchos países (Stafford, 2000). La UE, por ejemplo, ha reglamentado la comercialización de productos fitosanitarios, y fijado niveles máximos permitidos de residuos en los alimentos. También ha regulado la protección de la

calidad del agua con relación a los fitosanitarios (CE, 2003).

Como se vio en la sección anterior, para que la aplicación de técnicas de AP sea rentable, primero es necesario demostrar que existe una variabilidad espacio-temporal en las condiciones del campo. En concreto, en el caso del tratamiento selectivo de malas hierbas, es necesario estudiar cómo se distribuyen en el espacio y en el tiempo las malas hierbas, y cómo dichas distribuciones afectan al cultivo. En este tipo de estudios, son muchos los factores a tener en cuenta: por ejemplo fenómenos de competencia entre especies, la densidad de plantas de cada especie, en qué momento aparece cada una de las especies con respecto al cultivo, la proximidad entre malas hierbas y cultivo, cuáles son el momento y la forma óptimas de eliminar cada tipo de mala hierba, etc. (Pike et al., 1990; Weiner, 1982). Todo esto se estudia en *Malherbología*, ciencia pluridisciplinar que estudia la biología y el control de las malas hierbas.

Una vez analizada la ecología espacio-temporal de las malas hierbas (y siempre que se demuestre cierta variabilidad), deben redesarrollarse métodos para detectar las distintas especies y organizar la información de su localización (etapa de Percepción). A continuación, esta información debe interpretarse adecuadamente con el propósito de planificar la aplicación de tratamientos de modo que se eliminen todas las malas hierbas minimizando el uso de productos fitosanitarios (etapa de Actuación). Por último, una vez tratadas las malas hierbas se debe evaluar el resultado obtenido (malas hierbas eliminadas correctamente, rendimiento de la cosecha, cantidad ahorrada de fitosanitarios, etc.).

2.3.1. Estudio de la ecología espacio-temporal de las malas hierbas

Las malas hierbas más dañinas crecen y se distribuyen espacialmente de forma no uniforme, agrupándose en zonas, conocidas como “rodales” de malas hierbas. La agregación espacial ha sido demostrada claramente en el caso de varias especies perennes tales como *Cirsium arvense* o *Sorghum halepense* (Donald, 1994; Horowitz, 1973), o en algunas especies anuales como *Galium aparine* (Wallinga, 1995), *Abutilon theophrasti* (Dieleman y Mortensen, 1999) y *Orobancha crenata* (González-Andújar et al., 2001).

El estudio de estos patrones de agregación en las malas hierbas es muy reciente, por lo que las razones científicas que explican este comportamiento no están claras, como

2.3. Tratamiento selectivo de malas hierbas

tampoco es evidente la relevancia práctica de este hecho (Cardina et al., 1997). Conocer los factores asociados a la formación de rodales, ayudaría en el proceso de control de las malas hierbas. Del mismo modo, el control de las malas hierbas mejoraría si se conociese la evolución temporal de los rodales (estabilidad espacial). En definitiva, la construcción de mapas predictivos de infestaciones es una nueva línea de investigación importante (Main et al., 2004).

El estudio y cuantificación de los factores que llevan a la formación de rodales de malas hierbas es una tarea larga y ardua. Se necesita recoger información de la presencia de cada una de las distintas especies de malas hierbas en cada zona del campo durante varios años, y entender cuáles son los factores que han podido causar la distribución tanto espacial como temporal de cada especie, de entre el gran número de factores que afectan a un campo (meteorología, estado del suelo, geografía del terreno, crecimiento del cultivo, influencias externas por laboreo, etc.).

Para los anteriores estudios, se emplean los métodos clásicos de muestreo utilizados en ecología vegetal (estudio de la densidad, tasa de crecimiento y competitividad de cada especie, recogida de todos datos ambientales, etc.), combinados o no con el uso de sistemas de localización GPS que permiten una recogida georeferenciada de la información. Posteriormente todos los datos obtenidos se analizan habitualmente con métodos estadísticos o geoestadísticos. En esta exploración de los datos tienen especial importancia, para la elaboración de mapas, los SIG.

Por ejemplo, cultivos de maíz y soja en la zona central de los EEUU muestran la elevada asociación entre el relieve del terreno y algunas propiedades del suelo (materia orgánica, fertilidad) con la presencia y abundancia de diversas malas hierbas (Dieleman et al., 2000), mientras que en estudios llevados a cabo por la Universidad de Barcelona y la Universidad Politécnica de Cataluña se ha descubierto una relación entre la distribución espacial de *Lolium rigidum* y los surcos dejados por las cosechadoras (Blanco-Moreno et al., 2004).

Sobre la dinámica espacio-temporal de los rodales de distintas especies, las principales conclusiones obtenidas son que los rodales de determinadas especies de malas hierbas son estables (Webster et al., 2000a,b), mientras que otros no lo son (Perry y Lutman, 2000). Por ejemplo, estudios realizados en Andalucía por el equipo del Instituto de Agricultura Sostenible del CSIC han permitido establecer la estabilidad temporal de los

rodas de *Convolvulus arvensis* y su tasa de crecimiento interanual (Jurado-Expósito et al., 2003b, 2004; López-Granados et al., 2005).

2.3.2. Detección y muestreo de malas hierbas (Percepción)

En la etapa de percepción de un sistema de aplicación selectiva de tratamientos, se deben detectar e identificar las malas hierbas presentes en el campo, medir su densidad, y localizar su posición, con el propósito de crear un *mapa de cobertura de malas hierbas* o *mapa de infestación*. Este mapa muestra cómo está distribuida cada especie de mala hierba dentro del campo y con qué densidad. Ejemplos de estos mapas pueden verse en la figura 2.4.

Los mapas de infestación, se usan junto con otra información (por ejemplo mapas de cultivo o suelo, variables atmosféricas, etc.) en la etapa de toma de decisión para la construcción de *mapas de tratamiento* que indican qué cantidad de herbicida aplicar en cada zona.




Figura 2.4: Ejemplo de mapas de infestación. Estos mapas muestran cómo está distribuida cada especie de mala hierba dentro del campo (y con qué densidad). Los distintos niveles de densidad de malas hierbas se representan mediante escalas de colores

La elaboración de los mapas de infestación se realiza a partir de los datos obtenidos de un proceso de muestreo u observación del cultivo que puede ser de tres tipos: discreto, continuo o remoto (Senay et al., 1998).

Muestreos discretos

Los muestreos discretos, consisten en la recogida de información sólo en ciertos puntos preestablecidos del campo. Estos puntos suelen formar parte de una malla que cubre la totalidad del campo. La separación entre los puntos, o dimensión de la malla de muestreo, define la precisión del muestreo, y varía según el tamaño del campo, el tipo de infestación, y la precisión con la que se quiere llevar a cabo el tratamiento, variando entre $5 \times 5 \text{ m}^2$ y $50 \times 50 \text{ m}^2$ (Rew y Cousens, 2001). Por ejemplo, en Gerhards y Christensen (2003) se muestran las diferencias al usar una dimensión de malla de $3 \times 12 \text{ m}^2$ o de $7,5 \times 15 \text{ m}^2$, tal como se muestra en la figura 2.5.

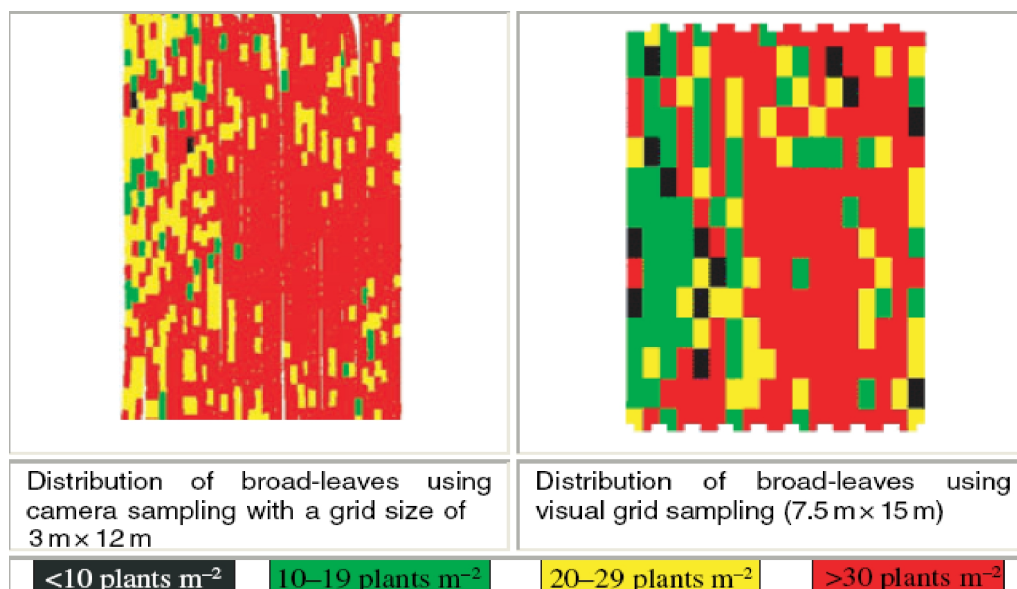


Figura 2.5: Distintos tamaños de malla de muestreo afectan a la formación del mapa de cobertura de malas hierbas (Gerhards y Christensen, 2003)

A partir de esta información discreta, se construye un mapa de cobertura de malas hierbas, utilizando distintas técnicas de interpolación, como por ejemplo el *kriging*, donde la extrapolación de los valores desconocidos se realiza de forma que el valor de los puntos más cercanos tendrá mayor influencia en la predicción que los valores de puntos más alejados (Cressie, 1993; Jurado-Expósito et al., 2003b). Otras formas de inferir información a partir de los datos recogidos en el campo son las técnicas

de autocorrelación (Dieleman y Mortensen, 1999) y los métodos de establecimiento de índices de distancia *Spatial Analysis by Distance Indices* (SADIE) (Perry, 1997; Perry y López-Granados, 1999). La elección del tamaño de la malla y la técnica de extrapolación son determinantes en la creación de un mapa que se ajuste al máximo a la realidad, ya que como se puede comprobar en la figura 2.5, distinto tamaño de malla no sólo varía la precisión sino que puede cambiar por completo el mapa obtenido.

Entre las técnicas de muestreo, la más habitual es la recogida de muestras de tierra en cada punto, y su posterior análisis en laboratorio mediante métodos gravimétricos, que dan lugar a una medida real de la densidad de cada especie encontrada, denominada *biomasa*. La biomasa mide el peso “seco” (para evitar errores producidos por el diferente contenido en humedad de las plantas) por unidad de superficie (generalmente gxm^2).

El procedimiento seguido para su cálculo es el siguiente: primero, se siega la parte aérea de las plantas (todo lo que queda por encima de la superficie del suelo) y se introduce cada especie en bolsas de papel perfectamente etiquetadas. Luego, las muestras se secan en una estufa, dejándose más o menos tiempo en función de la temperatura que se utilice (las combinaciones más normales son $103^{\circ}C$ durante 8h o $85 - 90^{\circ}C$ durante 24h). Una vez secadas, las muestras se pesan, dando una medida real de la densidad de plantas presente.

Aunque se trata de un método sencillo, es tedioso y costoso ya que requiere el desplazamiento al campo de numeroso personal especializado por lo que se utiliza con fines puramente de investigación (Rew y Cousens, 2001). Con vistas a facilitar esta tarea, podría pensarse en reemplazar el muestreo basado en cálculo de biomasa por un muestreo de estimación visual. Este tipo de muestreo es válido siempre que el crecimiento del cultivo y la mala hierba se encuentre en un estado inicial, para que la cubierta sea representativa de la cantidad de infestación a tratar, es decir, no hay plantas ocultas y por lo tanto existe una fuerte correlación entre la cubierta y la biomasa. La estimación visual, aunque menos costosa que la recogida de biomasa al no requerir el trabajo de laboratorio, es también una tarea tediosa ya que es necesario desplazar personal al campo con experiencia en el reconocimiento y la estimación de cobertura de malas hierbas.

Esta tarea se puede simplificar efectuando un muestreo fotográfico (recoger imágenes del campo en cada punto de muestreo), tarea que puede ser efectuada por un sólo

2.3. Tratamiento selectivo de malas hierbas

operario no especializado. Posteriormente, las fotos tomadas serían analizadas por el experto en el laboratorio. Este método presenta la ventaja, respecto de la apreciación directa en el campo, de poder observar las imágenes múltiples veces corrigiendo errores en la estimación. Aún así, la evaluación visual de fotografías, por parte de un experto, es un proceso muy subjetivo en el que se tiende a ajustar la apreciación a la situación global. Por ejemplo, si la mayoría de las imágenes del muestreo corresponde a situaciones de densidad baja de malas hierbas, la estimación de un experto de la cantidad de mala hierba en una imagen tenderá a ser más alta que en el caso en el que la mayoría de las imágenes de la colección presenten áreas con altas infestación de malas hierbas, (Andujar et al., 2009).

Esta situación de subjetividad en la estimación es la que determina la necesidad de desarrollar herramientas informáticas que permitan una estimación automática de la densidad de malas hierbas presentes en las fotografías. El objetivo es mejorar la precisión en la estimación reduciendo el coste del muestreo. La investigación orientada al desarrollo de estas herramientas informáticas de *procesamiento de imágenes* es un campo en pleno auge como lo demuestran la gran cantidad de trabajos de investigación publicadas en los últimos 10 años y que se presentarán con más detalle en el en el Capítulo 3.

Muestreos continuos desde suelo

Estos muestreos proponen recoger información de manera continua, en todos los puntos del campo, en contraposición con los muestreos discretos. Ahora bien, dado que es impensable recoger muestras del suelo en toda la superficie del campo, para ser capaces de realizar estos muestreos se necesitan herramientas de detección de malas hierbas capaces de estimar a través de un flujo continuo de imágenes (vídeo) del cultivo la densidad de malas hierbas. Asimismo estas herramientas de detección deben ir conectadas a algún sistema de localización de posición o de velocidad, que permita almacenar cada valor estimado de densidad de malas hierbas con su posición en el campo global o relativa, y así construir el mapa de cobertura de malas hierbas.

Los sensores utilizados para la detección de malas hierbas varían mucho en función del tipo de infestación a detectar y del tipo de cultivo. Por ejemplo, en casos en los

que la mala hierba está claramente separada del cultivo, pueden usarse sensores optoelectrónicos, que son capaces de discriminar entre plantas y otros materiales (suelo, paja). Este es el caso de trabajos de detección de malas hierbas en barbechos o cultivos leñosos (Blackshaw et al., 1998; Felton y Nash, 1998), o en casos donde las líneas de cultivo están muy separadas y las malas hierbas crecen entre ellas como el maíz o la remolacha, (Biller et al., 1997). En casos en los que las malas hierbas no se encuentran tan separadas del cultivo pero sin embargo puedan ser detectadas por diferencias en el color, textura, forma, posición, etc., son útiles las técnicas de Visión Artificial, que permiten el procesamiento de las imágenes tomadas con cámaras de vídeo digitales, y que se presentarán en el Capítulo 4.

En la mayoría de los casos la información extraída en estos muestreos suele ser menos precisa que la información obtenida de muestreos discretos, debido a las limitaciones en tiempo disponible, estimando por ejemplo la densidad de mala hierba en clases (cero/bajo/medio/alto) o incluso simplemente por la presencia/ausencia de ésta (sensores optoelectrónicos).

Entre los cuellos de botella de estos muestreos se encuentran la alta dependencia con la tecnología (sistema GPS, sensores de detección, equipo PC portátil, programas informáticos de adquisición de datos, etc.), y la necesidad de personal altamente cualificado para llevar a cabo el muestreo. Otra de las dificultades más importantes es detectar visualmente la infestación de forma suficientemente rápida, adaptándose a todas las situaciones distintas encontradas (estados de crecimiento, cantidad de infestación, etc.). A día de hoy, los pocos trabajos de investigación existentes en este contexto presentan muestreos muy simplificados o que funcionan sólo bajo condiciones específicas.

En consecuencia, el desarrollo de toda esta tecnología es altamente deseable, siendo un objetivo común dentro de la comunidad de los investigadores en AP, ya que el muestreo continuo visual ofrece beneficios evidentes con respecto a los otros tipos de muestreos, al ser los mapas resultantes sin duda los que mejor se ajustan a la realidad. Más importante aún, ser capaces de efectuar un muestreo continuo puede llevar a la aplicación de tratamientos directos (en tiempo real), si los métodos de detección de malas hierbas son lo suficientemente rápidos. Es decir, si el sistema es capaz de detectar y posicionar las malas hierbas de forma continua a la vez que el tractor recorre el campo, y si lo hace a tiempo de controlar la apertura y cierre de las boquillas de pulverización.

Muestreos remotos

Estos muestreos consisten en captar información del campo sin entrar en contacto físico con él, mediante el uso de técnicas de teledetección. Para ello, se utilizan sensores remotos, instalados en aviones o satélites, que miden la energía electromagnética reflejada por la superficie terrestre y los elementos que en ella se encuentran (como plantas, edificios, etc.). Distintos sensores pueden medir la radiancia en distintas longitudes de onda, dependiendo de cuál sea la franja que se quiere estudiar: espectro visible ($400 - 700nm$), infrarrojo cercano/medio ($700nm - 8m$), sensores térmicos ($8 - 14m$), etc. Las técnicas de teledetección no sólo se aplican en muestreos, sino que se usan a menudo para obtener información sobre el medioambiente y los recursos naturales (Barret y Curtis, 1992).

Su utilización en el muestreo de malas hierbas se fundamenta en el hecho de que cada especie de planta refleja y emite energía de forma distinta, llamada *signatura espectral* (Chuvieco, 1996). Por lo tanto, conociendo la *signatura espectral* del cultivo y de cada una de las especies de malas hierbas a detectar, y escogiendo el sensor adecuado para la zona del espectro que se desea analizar (aquella en la que haya más diferencias), a partir de los valores de radiancia se puede automáticamente clasificar cada especie. La posición, al tratarse de imágenes aéreas, se obtiene a partir de un procedimiento de composición llamado *mosaico* que utiliza la información de posición del avión o satélite.

Para hallar la *signatura espectral* de cada especie, se miden la radiancia, irradiancia, reflectividad o transmisión de las plantas sobre el terreno. Para ello se utilizan espectroradiómetros portátiles que recogen información (*Radiometría de campo*) desde el visible al infrarrojo medio (dependiendo del tipo de instrumento) en un espectro continuo.

Para llevar a cabo este muestreo, se deben cumplir dos requisitos: 1) la existencia de diferencias espectrales significativas entre las malas hierbas, suelo y plantas de cultivo, 2) que la resolución espacial y espectral del sensor de teledetección utilizado sean adecuadas para detectar la presencia de los rodales de malas hierbas que tienen que ser tratados (Brown y Steckler, 1995; Lamb et al., 1999; Vrindts, 2000).

En el caso de las imágenes obtenidas por satélites el problema principal del muestreo reside muchas veces en la baja resolución del mapa de infestación obtenido, al tratarse de imágenes tomadas desde alturas considerables, y en el alto coste económico

asociado con la toma de imágenes desde satélite. En el caso de imágenes tomadas desde aeronaves especializadas, la situación en precisión mejora, pues la altura es considerablemente inferior, pero sigue siendo un servicio costoso. Además, ambos métodos son muy dependientes de las condiciones meteorológicas. Una alternativa es la adquisición de imágenes con aeronaves no tripuladas. En este caso surgen otros problemas con el tiempo de autonomía, el peso de los equipos (cámaras) que tienen que ir a bordo, etc.

2.3.3. Aplicación selectiva de tratamientos (Actuación)

Una vez demostrada y detectada la variabilidad espacio-temporal de las malas hierbas, el siguiente paso es la aplicación de tratamientos selectivos que se ajusten a las necesidades específicas de cada zona, reduciendo los costes de la producción y la contaminación (Stafford y Miller, 1993).

A la hora de interpretar los datos recogidos en la etapa de percepción para llegar a una actuación real en el campo, son muchos los factores a tener en cuenta. Antes de nada, hay que distinguir entre los sistemas de aplicación de tratamientos en tiempo real, y aquellos basados en información previa.

Los sistemas de aplicación de tratamiento en tiempo real se componen de sensores de detección, situados sobre el tractor, unos programas de análisis que en función de los datos recogidos por los sensores determinen la cantidad de mala hierba y unos mecanismos de control sobre el equipo de tratamiento. La decisión sobre la actuación debe tomarse en tiempo real, a la vez que el tractor se desplaza sobre el campo, siendo las velocidades de avance habituales para la aplicación de tratamientos de entre 4 y 8Km/h. Esto significa que el tiempo entre la captura de la imagen y la actuación se sitúa alrededor de dos a tres segundos.

Los sistemas basados en información previa, sin embargo, pueden usar métodos de toma de decisiones complejos, ya que disponen de todo el tiempo necesario para construir un mapa de tratamiento preciso a partir de un mapa de infestación. Estos sistemas pueden además incorporar sin dificultad en su decisión más variables (variables atmosféricas, competitividad de cada especie, etc.), mientras que en el caso de los sistemas en tiempo real, la incorporación de más información dependerá del tiempo de cómputo requerido en la toma de la decisión.

2.3. Tratamiento selectivo de malas hierbas

Todo lo expuesto explica que en la actualidad los sistemas de tiempo real tomen decisiones en función directamente de la densidad estimada de mala hierba presente (Tellaecche et al., 2008b), mientras que los sistemas basados en información previa incluyan sistemas de soporte a la decisión que determinan el impacto de la dosis de herbicida sobre los rendimientos del cultivo, teniendo en cuenta una variedad amplia de factores. Por ejemplo, cabe destacar el algoritmo de decisión *DAPS* (Christensen et al., 2003), para el control de cultivos de cereales, en el cual la dosis de aplicación del herbicida se calcula en función de la densidad de diferentes especies de malas hierbas, su competitividad relativa y los parámetros de las curvas de dosis-respuesta de los diferentes herbicidas.

En un punto medio entre sistemas de decisión en tiempo real y sistemas extremadamente complejos se pueden encontrar sistemas de decisión basados en lógica borrosa (Yang et al., 2003), o en aprendizaje mediante redes neuronales (Goel et al., 2003; Gutiérrez-Peña et al., 2008).

A la hora de efectuar el tratamiento, ambos enfoques (tiempo real o información previa) comparten las mismas preocupaciones intrínsecas sobre cómo los productos fitosanitarios afectan a las malas hierbas. Por ejemplo, a la hora de decidir la cantidad de herbicida a aplicar, se puede utilizar un umbral de tratamiento y usar dosis máxima siempre que se supere dicho umbral o bien ajustar la dosis en relación directa con la densidad de mala hierba encontrada. Sobre cómo tratar distintas especies de malas hierbas, también existen dos formas: tratar independientemente cada especie con herbicidas específicos o realizar un único tratamiento con una mezcla de productos.

La única manera de determinar el mejor tratamiento es evaluar distintas configuraciones sobre el cultivo a tratar. Dicha evaluación generalmente se limita a determinar la cantidad de herbicida ahorrado comparado con las técnicas tradicionales (además de asegurarse de que se ha eliminado la totalidad de las malas hierbas y que el rendimiento del cultivo no ha sufrido cambios). Las cifras obtenidas y las configuraciones evaluadas varían considerablemente dependiendo del cultivo, de la especie de mala hierba y de su distribución espacial en la parcela.

En experimentos reales, son muchos los trabajos que han demostrado los beneficios de los tratamientos selectivos frente a técnicas tradicionales. En (Heisel et al., 1997), uno de los primeros trabajos de evaluación, ya se demostró una reducción potencial

del uso de herbicidas de un 59 %. En (Luschei et al., 2001) o (Goudy et al., 2001) se llevaron a cabo estudios sobre campos de cereales durante varios años, demostrándose en ambos casos un ahorro neto de fitosanitario sin reducir la eficacia del control de la infestación. Estudios llevados a cabo en periodos de 6 a 10 años en el centro de Europa en campos de cereal de invierno, han mostrado que generalmente los ahorros se sitúan por encima del 40 % (Homouz, 2007; Nordmeyer, 2007). Estudios realizados por el Centro de Ciencias Medioambientales del CSIC con infestaciones de *Avena sterilis* en cultivos de cebada en diversas regiones españolas indican ahorros de entre un 61 % y un 74 % (Ruiz et al., 2006). En los EE.UU., resultados de diversos estudios muestran que los beneficios netos obtenidos mediante la aplicación selectiva de tratamientos en maíz, soja y sorgo permiten incluso cubrir todos los gastos asociados a dichos tratamientos (Rider et al., 2006).

El uso de técnicas de simulación es una alternativa rápida y barata a la experimentación en campo. Paice y Day (1997) presentó un modelo espacio-temporal de control de *Alopecurus myosuroides* llevando a cabo simulaciones a largo plazo para comparar la aplicación de la dosis completa de herbicida cuando la densidad de malas hierbas en una zona era superior a un cierto umbral, con tratamientos donde se ajustaba la dosis de herbicida a la densidad de malas hierbas en la zona. Los resultados mostraban que la segunda estrategia ofrecía una mayor rentabilidad económica y una mayor fiabilidad, con un menor riesgo de que se establecieran nuevas poblaciones. Posteriormente este modelo fue perfeccionado introduciendo procesos estocásticos y modelos de dispersión de semillas (Paice et al., 1998). Combinando este modelo con el algoritmo de decisión DAPS, en Christensen et al. (1999) se obtuvieron unos resultados que mejoraban frente a otras estrategias de control en términos de rendimientos del cultivo, niveles de infestación y cantidad de herbicida aplicado.

Los dos factores críticos para que los tratamientos selectivos sean rentables, (Paice, 2000), son el patrón de agregación de las malas hierbas, el porcentaje del campo infestado, el tamaño medio de los rodales y la resolución espacial de los tratamientos (tamaño de la unidad mínima de terreno que puede ser tratada selectivamente). Por ejemplo, algunos estudios experimentales indican que en campos de cebada con más de un 50 % de su superficie infestada por *Avena fatua* la utilización de tratamientos localizados puede no ser rentable económicamente, mientras que en campos con 46 y 40 % de su superficie infestada se obtienen grandes beneficios (Luschei et al., 2001). Estudios sobre

2.3. *Tratamiento selectivo de malas hierbas*

la resolución espacial de los tratamientos indican que para que el tratamiento selectivo sea rentable se deben tratar diferencialmente como mínimo zonas de $6 \times 6 m^2$ (Paice et al., 1998).

El mayor problema potencial de la aplicación selectiva de tratamientos, es el posible incremento de las poblaciones de malas hierbas en aquellas zonas en las que años anteriores no se aplicaron las dosis máximas de fitosanitarios. Sin embargo, los escasos estudios sobre el tema descartan esta hipótesis, no habiéndose observado ningún incremento de poblaciones de malas hierbas en zonas nuevas durante un periodo de 10 años (Dick y Krohmann, 2007).

Capítulo 3

Visión Artificial aplicada a la agricultura

¿A quién va usted a creer, a mí o a sus propios ojos?

Groucho Marx

3.1. Introducción a la Visión Artificial

Los sentidos de un ser vivo, junto con las experiencias vividas anteriormente, forman su percepción del entorno que le rodea, a través de la cual modela la forma de desenvolverse en él. De todos los sentidos de los que dispone el ser humano, la vista es sin duda el más importante y complejo. Nuestro sistema visual se compone de más de dos millones de fibras nerviosas, frente a las sólo treinta mil fibras dedicadas al sentido auditivo, por ejemplo.

En el afán de dotar a las máquinas de capacidades similares a las de los seres vivos, desde el principio de disciplinas como la Robótica o la Inteligencia Artificial (IA), se

han abierto líneas de investigación importantes relacionadas con el estudio y desarrollo de sistemas de Visión Artificial para dotar a las máquinas de sentido visual. Y es que dotar a las máquinas de sistemas de percepción visual puede capacitarlas para resolver muchos problemas que de otro modo quedarían sin resolver, y más aún, permite resolver muchos problemas de forma más directa, mejorando en muchos casos tanto la eficiencia del proceso como la facilidad de su implementación.

El término Visión Artificial (VA) engloba todas aquellas técnicas que llevan a emular la visión de los seres humanos (o de cualquier otro ser vivo) de forma artificial. Debido a que la VA es un concepto muy amplio, variado y altamente pluridisciplinar, en la literatura se pueden encontrar distintos términos que separan la VA en subgrupos según el entorno de aplicación o las tareas realizadas. Un ejemplo clásico es separar la *Visión Máquina* de la *Visión por Computador* según si las técnicas de visión se aplican en entornos industriales o no, o el hablar de *Procesamiento de Imágenes* como de algo distinto de la VA. Sin embargo, el uso de estos términos puede llevar a confusión, dado que cada parte tiene muchas cosas en común con las otras, siendo difícil discernir dónde empieza una y acaba la otra. Más aún, esta confusión aumenta en castellano debido a que la traducción de la terminología inglesa original no está estandarizada. Por ejemplo, algunos autores traducen el término inglés *Computer Vision* como *Visión por Computador*, mientras que otros lo hacen directamente como *Visión Artificial*. Por todo ello, en esta memoria se ha preferido no hacer distinciones y hablar siempre de Visión Artificial (VA).

El desarrollo de la VA involucra muchas disciplinas distintas: desde la Óptica y Electrónica de los objetivos, sensores y cámaras usadas, a la Neurobiología para entender y emular el funcionamiento del órgano visual de cualquier ser vivo, pasando por las Matemáticas para la formación, el manejo y las operaciones sobre imágenes o la Inteligencia Artificial para aprender y mejorar el procesamiento de las imágenes, entre otras. Las aplicaciones de la VA también son extremadamente variadas. De hecho, a día de hoy, prácticamente no hay área en la que no se haya aplicado alguna vez alguna técnica de VA: medicina, astronomía, ingeniería, agricultura, robótica, etc.

A pesar de que el tratamiento de imágenes y uso de sensores especiales se remonta a principios del siglo XX (McFarlane, 1972), no es hasta finales de los años 70 cuando despegue la VA, momento en el que se empieza a disponer de muchos de los compo-

3.1. Introducción a la Visión Artificial

nentes necesarios para desarrollar sensores electrónicos capaces de captar el entorno almacenando la información en formato digital, o microprocesadores con capacidades de cálculo que permiten manejar, programar y procesar grandes conjuntos de datos como son las imágenes. De entre los principales hitos que hicieron posible la aplicación de técnicas de VA cabe destacar el desarrollo de sensores de imagen digitales, el primer microprocesador, la aparición del primer PC, de los primeros Sistemas Operativos y lenguajes de programación, o la aparición de circuitos integrados VLSI, entre otros (Gonzalez y Woods, 2003).

Una forma común de dividir las aplicaciones de la VA es según el tipo de sensor usado, o lo que es lo mismo, según de qué naturaleza son las imágenes tomadas por dicho sensor o cámara. Mientras que la vista de los seres humanos sólo es sensible a un determinado rango de radiación electromagnética, conocida como *luz visible*, en la VA se usan sensores sensibles a prácticamente cualquier rango de radiación electromagnética.

Referido a un objeto se denomina *espectro electromagnético* o simplemente *espectro*, a la radiación electromagnética que emite (espectro de emisión) o absorbe (espectro de absorción). Para cada una de estas radiaciones, los fotones (las partículas portadoras de todas las formas de radiación electromagnética) difieren en la frecuencia y en la longitud de onda. Dado que la velocidad de las ondas electromagnéticas es constante (velocidad de la luz, c), la longitud de onda (λ) y la frecuencia (f) son inversamente proporcionales ($\lambda = c/f$, siendo $c = 299.792.458 \text{ m/s}$). La energía asociada a cada fotón es inversamente proporcional a la longitud de onda ($E = \frac{hc}{\lambda}$, siendo $h = 6,62 \times 10^{-34} \text{ J} \cdot \text{s}$, *constante de Planck*). Se cree que el rango de posibles longitudes de onda de la radiación electromagnética tiene como límite inferior la *Longitud de Planck* ($l_P = 1,61 \times 10^{-35} \text{ m}$) y como límite superior el tamaño del universo (desconocido), aunque no se ha demostrado, y formalmente el rango de posibles radiaciones es infinito y continuo.

La figura 3.1 muestra el subrango del *espectro electromagnético* con longitudes de onda desde 10^{-15} m hasta 10^5 m , y frecuencias asociadas de 10^{23} Hz hasta 10^3 Hz . La radiación de menor longitud de onda corresponde a los rayos gamma, y a medida que aumenta ésta y disminuye la energía asociada a dicha radiación, se encuentran los rayos X, la luz ultravioleta, la luz visible, los rayos infrarrojos, hasta las ondas electromagnéticas de mayor longitud de onda, como las ondas de radio.

Gracias a que cada elemento puede identificarse por su radiación electromagnética,

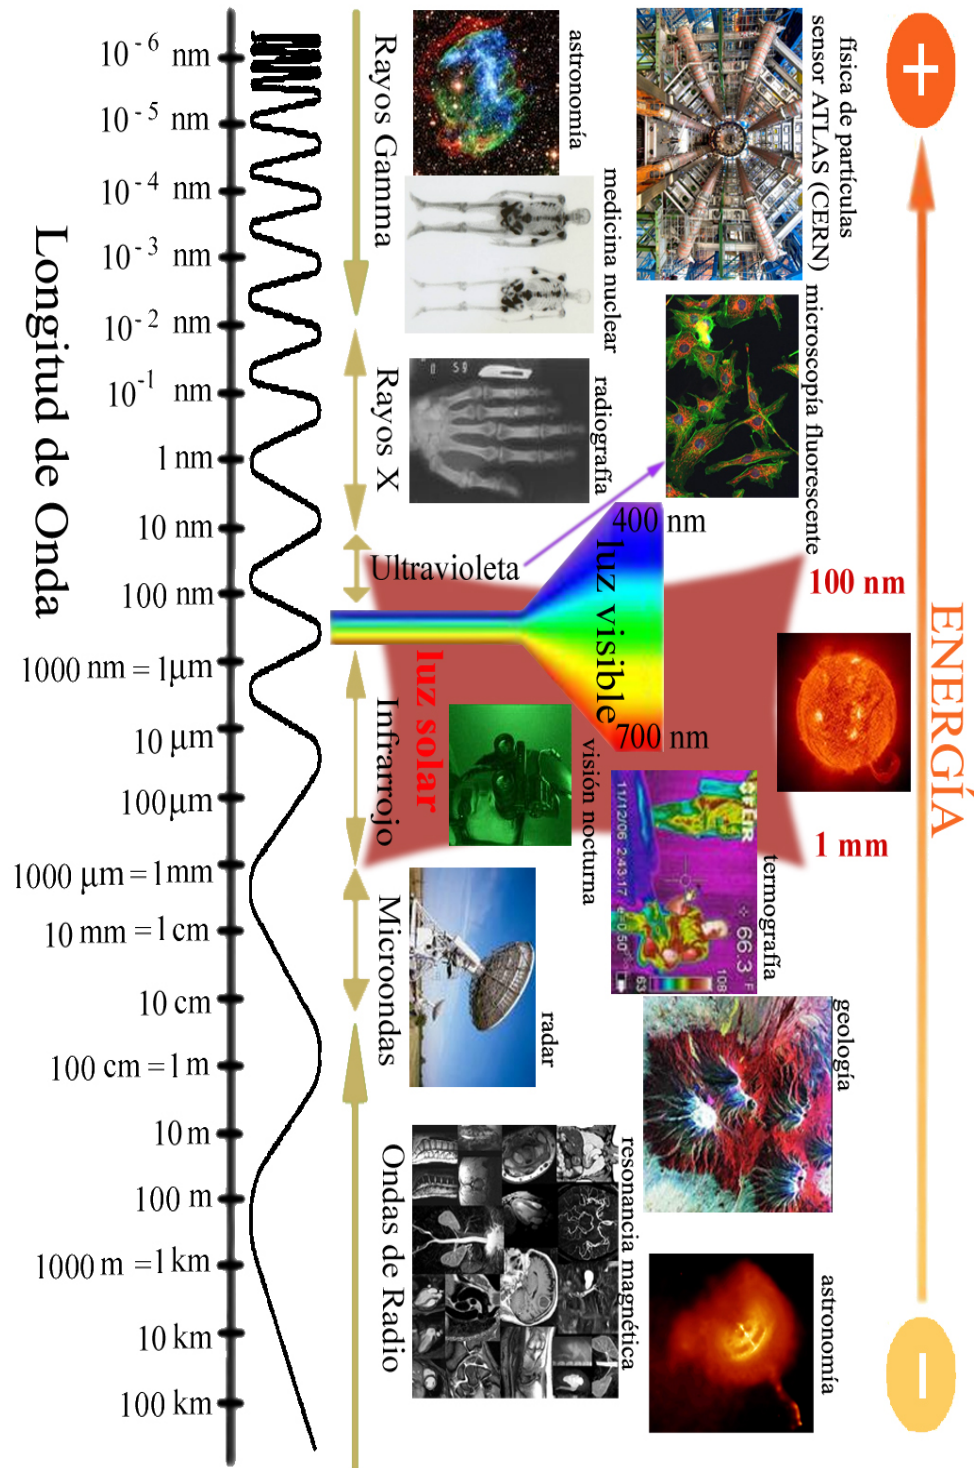


Figura 3.1: El espectro electromagnético

3.1. Introducción a la Visión Artificial

sensores sensibles a distintos rangos del espectro electromagnético pueden usarse para distintos fines. En la figura 3.1 se muestran algunas de las aplicaciones de la VA dentro de cada rango:

- **Rayos Gamma:** esta radiación la producen generalmente elementos radioactivos, procesos subatómicos, o fenómenos astrofísicos de gran violencia. Por ello, la medición de radiación gamma es de gran importancia en física de partículas y astronomía. Otro campo de aplicación de los rayos gamma es la medicina nuclear, como por ejemplo la inyección de isótopos radioactivos por vía intravenosa y la medición de los rayos gamma emitidos por éstos para detección de tumores o infecciones, o la cintigrafía ósea.
- **Rayos X:** Los rayos X son capaces de atravesar cuerpos opacos, por lo que son usados en infinidad de aplicaciones como medicina (radiografía, angiografía, tomografía axial computerizada), vigilancia, astronomía o incluso en procesos industriales, como por ejemplo el diagnóstico de placas electrónicas, motores, etc.
- **Ultravioleta:** Las aplicaciones de la luz ultravioleta, aunque menos conocidas, son muy variadas: desde astronomía, biología, litografía o microscopía fluorescente usada por ejemplo para detectar sustancias con autofluorescencia (como la vitamina A).
- **Luz visible:** Dado que el espectro visible es el que mejor conoce y maneja el ser humano, las aplicaciones de la luz visible son innumerables, abarcando prácticamente todas las áreas. Sus fundamentos y aplicaciones en los campos de más interés dentro del ámbito de esta Tesis se estudian más adelante, en este mismo capítulo.
- **Infrarrojo:** Las aplicaciones de la radiación infrarroja también son muy diversas: vigilancia nocturna, supervisión mediante imágenes térmicas (construcción, industria, medicina, astronomía...) y sobre todo imágenes de nuestro planeta tomadas por satélites. Muy a menudo, se combina la información infrarroja con la del espectro visible, creando imágenes “reales” fusionadas con información infrarroja. De hecho, la mayoría de los sensores usados en las cámaras convencionales son también sensibles a radiación infrarroja, aunque esta información se filtra para que las fotografías no resulten dañadas.

- **Microondas:** La aplicación principal de las microondas en visión es el uso del radar, capaz de “ver”, independientemente de las condiciones ambientales o de iluminación, traspasando nubes, vegetación, arena, etc. Además del uso militar, este tipo de imágenes se emplean en Geología, para tomar fotos de regiones inaccesibles, como por ejemplo volcanes.
- **Ondas de Radio:** Al igual que con los rayos gamma, las mayores aplicaciones de visión con ondas de radio están localizadas en la medicina (resonancia magnética) y la astronomía.

También se pueden considerar como VA las técnicas orientadas a dotar de visión a personas invidentes. Existen enfermedades que afectan a las células fotorreceptoras de la retina pero no dañan las células ganglionares o el nervio óptico, que es el encargado de interpretar y mandar al cerebro la información visual captada. Es decir, el problema está en la adquisición de la información y no en cómo ésta alcanza el cerebro. Por ello, actualmente se investiga el desarrollo de microchips de silicio que puedan reemplazar a las células fotorreceptoras de forma artificial, como el “ojo biónico” Argus II desarrollado en EE.UU. (Argus2a, 2009).

Es importante destacar que las imágenes resultado del uso de una única cámara, plasman el entorno tridimensional en un plano. Por lo tanto, es de gran importancia el desarrollo de técnicas de visión *estereoscópica*, que permiten, con la información de dos cámaras, hacer una reconstrucción total, en tres dimensiones, de la escena. Esto es útil sobre todo cuando la información sobre la distancia a los objetos es importante, como por ejemplo en robótica cuando se quiere interactuar con el entorno (manipular objetos, navegar autónomamente salvando obstáculos, etc.). Spirit, el robot enviado a Marte por la NASA en el 2004, usa este tipo de técnicas, figura 3.2.

Dentro de este inmenso mosaico de aplicaciones y posibles configuraciones de cámaras, y en términos generales, las tareas llevadas a cabo mediante técnicas de VA pueden resumirse como sigue (ver figura 3.3):

- **Adquisición de información “visual” del entorno:** Adquisición de imágenes, vídeo (secuencia de imágenes), u otras formas de señales “visuales” de la escena mediante distintos tipos de sensores o cámaras, sensibles a distintas ondas como radiaciones electromagnéticas o sonido.




Figura 3.2: Visión estéreo usada por el robot Spirit en Marte. En la izquierda puede verse la imagen captada por una de las dos cámaras, y a la izquierda el mapa de elevación calculado al fusionar las imágenes de ambas cámaras (NASA, 2008)

- **Mejora y restauración de imágenes:** Técnicas como el suavizado y realzado orientadas a mejorar la calidad de una imagen, o procesos de restauración que intentan reconstruir una imagen degradada usando conocimiento a priori del proceso de degradación.
- **Reconocimiento y descripción de patrones, formas y puntos de interés:** La identificación, clasificación y descripción de cualquier elemento presente en una imagen considerado de interés.
- **Análisis del movimiento:** Detección de la presencia de objetos en movimiento en una secuencia de imágenes.
- **Reconstrucción de la escena:** Obtención de la distancia a los objetos en la escena (visión estereoscópica), o reconstrucción de la estructura tridimensional de un objeto.

Durante la adquisición de imágenes, en la mayoría de los casos la *iluminación* de la escena juega un papel fundamental, como se verá más adelante. Por iluminación se

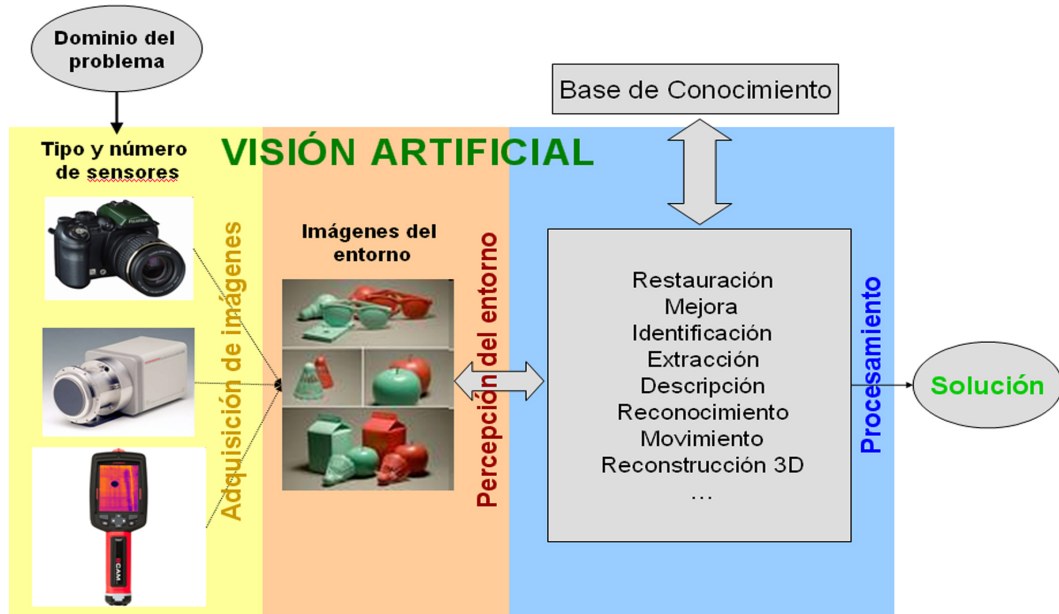


Figura 3.3: Tareas principales de la VA

entiende cualquier fuente de onda que haga *visible* la escena, pudiendo ser lámparas de luz visible o la luz natural del sol, pero también otros tipos de iluminación que no siempre se perciben como los rayos X, el láser, los ultrasonidos, etc.

El abanico de estrategias y aplicaciones de la VA es muy extenso. Más información puede encontrarse en (Gonzalez y Woods, 2003; Jai, 1989; Pajares y de la Cruz, 2007; Russ, 2002).

3.2. Fundamentos de la Visión Artificial

En esta sección se explican brevemente algunos de los fundamentos de las técnicas de VA estudiadas y usadas en esta tesis, con vistas a facilitar la comprensión de los procedimientos propuestos. En este caso, y aunque se mencionarán otras técnicas, fundamentalmente siempre se tratarán de métodos que usan imágenes digitales tomadas mediante cámaras convencionales, es decir, sensores sensibles exclusivamente al espectro

visible o como mucho al infrarrojo cercano (NIR, Near InfraRed).


3.2.1. Adquisición de imágenes digitales

Los sensores de imagen son sensores basados en el *efecto fotoeléctrico*, que consiste en la emisión de electrones por parte de un material tras la absorción de energía proveniente de los fotones. Los electrones emitidos se denominan habitualmente fotoelectrones. Dependiendo de la naturaleza de la radiación electromagnética, los fotones tendrán energías distintas, y distintos materiales emitirán electrones sólo para algunas energías.


El elemento básico de un sensor de imagen es el fotodetector (que reemplaza a la película fotográfica). Un fotodetector es un transductor de luz que proporciona una señal eléctrica como respuesta a la radiación óptica que incide sobre la superficie del sensor. Está formado por materiales fotosensibles que emiten electrones cuando los fotones de luz inciden sobre ellos, creándose una carga eléctrica proporcional a la intensidad de luz recibida. Los fotodetectores tienen tamaños diminutos (en un área de 37cm^2 pueden caber diez millones) y se distribuyen en forma de matriz de pequeñas celdas perfectamente alineadas en filas y/o columnas. Los dos principales sensores usados por prácticamente todas las cámaras convencionales se distinguen por su funcionamiento interno y por la tecnología usada y son: 1) Charge-coupled device (CCD) y 2) Complementary metal-oxide-semiconductor (CMOS) (llamados también Active Pixel Sensors (APS)), figuras 3.4 y 3.5.

El CCD se divide en dos partes: la parte fotosensible (una lámina de silicona compuesta por un alto número de diminutos fotodetectores) y la parte de transmisión (circuitaría electrónica). Cada fotodetector desplaza la carga generada a su vecino, usando registros de desplazamiento. El último detector de cada línea de la matriz de sensores pasa su carga a un amplificador que transforma la carga eléctrica en voltaje. Posteriormente, dicho voltaje se digitaliza. El nombre CCD se refiere a la forma en la que son transmitidas las cargas eléctricas de cada fotodetector y transformadas a señales digitales.

En el CMOS, los detectores fotosensibles son fotodiodos basados en tecnología CMOS, habitualmente de silicio. La diferencia con los CCD radica en que en los CMOS,



(a) CCD, 10 Mp, Nikon D60



(b) CMOS, 12.3 Mp, Nikon D3

Figura 3.4: Ejemplo de sensores CCD y CMOS. Mp = Mega Píxeles o Millones de píxeles (resolución de las imágenes)

cada fotodiodo incorpora directamente el amplificador de la señal eléctrica y el convertor digital, por lo que los valores registrados por cada detector se “leen” de forma simultánea.

Los sensores CCD tienen mayor sensibilidad a la luz, más calidad y también precio más alto, mientras que los de tipo CMOS son menos sensibles y de menor calidad, pero al ser fáciles de fabricar son más baratos. Normalmente se han usado los CCD para las cámaras profesionales y semiprofesionales y los CMOS para las cámaras de aficionados y Webcams.

Sin embargo, recientemente algunas cámaras semi-profesionales han basado su tecnología en sensores CMOS con alto rendimiento. El interés en el CMOS radica en su menor coste de producción, de hecho, la fabricación de CCDs, debe hacerse en plantas especializadas a partir de materias primas escasas y por tanto caras, mientras los CMOS pueden ser fabricados en las líneas convencionales de producción de semiconductores a partir de materias primas más baratas y de uso generalizado, ya que se trata de la misma tecnología que la de los microprocesadores.

En términos generales, el CMOS es aún demasiado sensible al ruido, tiene un rango dinámico reducido y presenta poca sensibilidad, pero a cambio sus características

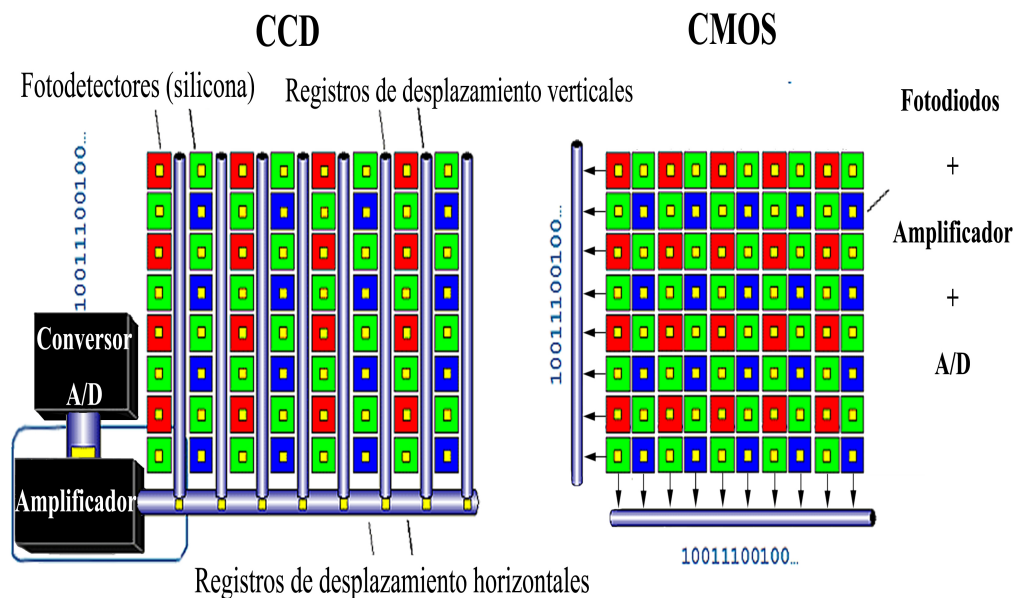


Figura 3.5: Esquema de funcionamiento de los sensores CCD y CMOS

estructurales son mejores que las del CCD, ya que permite una interpolación de la imagen más directa, y evita el efecto de *blooming* existente en los CCDs, es decir la contaminación entre píxeles vecinos cuando hay situaciones de sobreexposición. Más aún, el consumo de los CMOS es muy inferior al de los CCDs (50 mW frente a 5W).

3.2.2. Formación de imágenes digitales

Una imagen digital, ya sea una fotografía, un fotograma de un vídeo o un gráfico, se trata como una función bidimensional $f(x, y)$, donde el valor de la función en el punto (x, y) representa la intensidad de luz observada en dicho punto. Los puntos reciben el nombre de *píxel* y constituyen la unidad elemental de una imagen. Con frecuencia, y con el propósito de manipular la información, las imágenes se representan como matrices, donde un elemento en la fila y y en la columna x representa la intensidad del píxel (x, y) , figura 3.6. La resolución de la imagen, no es más que el tamaño de la matriz (nº de filas x nº columnas), figura 3.7. Las resoluciones se suelen medir en términos de *Mega Píxeles (Mp)*, o lo que es lo mismo, millones de píxeles.




Figura 3.6: Imagen digital como matriz de píxeles

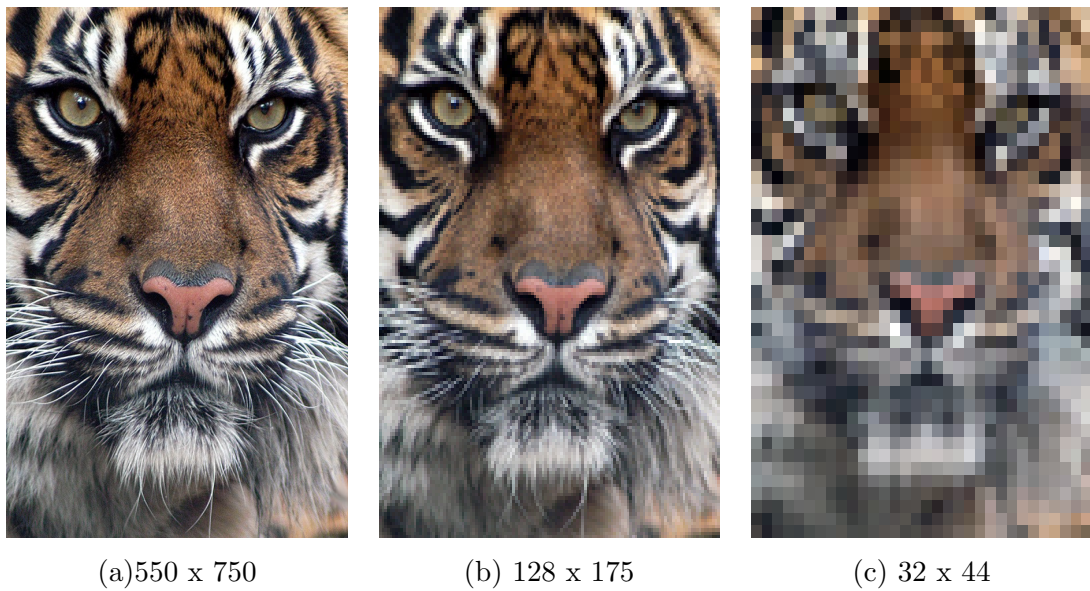


Figura 3.7: Resolución de una imagen (número de píxeles)

3.2. Fundamentos de la Visión Artificial

Al rango de valores de intensidad se le llama *profundidad* de los píxeles, y define la *resolución en intensidad* de una imagen. En la figura 3.8 puede verse el efecto de distintas profundidades sobre la misma imagen. Normalmente en una imagen en escala de grises, cada píxel se codifica con 8 bits, por lo que el rango de valores (profundidad) es de $0 \dots 2^8 - 1 = 0 \dots 255$, figura 3.8(a).



Figura 3.8: Profundidad de los píxeles. Foto cortesía de National Geographic (Steve McCurry), portada de la edición de Junio, 1985.

Para formar imágenes a color, se necesitan varios *canales* o *planos* de color. Cada canal representa valores de intensidad dentro del correspondiente rango espectral visible, y al combinar varios canales se puede formar la imagen a color, del mismo modo que un pintor mezcla colores de la paleta para alcanzar el color deseado. El modelo de color más usado en imágenes digitales es el RGB (Rojo, Verde, Azul), que es el que más se ajusta al funcionamiento del ojo humano y propio de los monitores. Otro modelo muy usado es el CYMK (Cian, Amarillo, Magenta, Negro) también llamado de *pigmentación*, modelo propio de las impresoras. En una imagen RGB, cada píxel tiene información de los tres planos, estando la imagen formada por tres matrices distintas que recogen el valor de la intensidad de los píxeles para cada uno de los planos Rojo, Verde y Azul, figura 3.9.




Figura 3.9: Formación de una imagen RGB como combinación de los canales rojo, verde y azul, donde cada canal es una matriz de intensidades. Cada píxel tiene tres valores asociados. Cuadro de Vasilij Kandinskij (Moscú I), 1916

La construcción de imágenes a partir de la intensidad de luz absorbida por cada fotodetector (en cualquiera de los sensores anteriores, CCD o CMOS) no es tan directa como cabría esperar. Los fotodetectores perciben las variaciones de intensidad de la luz tanto dentro del espectro visible e infrarrojo cercano (hasta unos 1100nm) sin distinguir entre éstos, ni entre los distintos colores del espectro visible.

Para bloquear el paso de la radiación infrarroja, basta con colocar un filtro bloqueante sobre la parte fotosensible del sensor. Habitualmente, en las cámaras convencionales se utiliza el filtro *Hot Mirror* (HM), un filtro común de fotografía o filtro dieléctrico.

Del mismo modo, para formar imágenes a color, se emplean filtros para cada fotodetector de modo que éste sea sensible sólo a un color determinado, y posteriormente se combina la información de colores para formar cada píxel de la imagen. La imagen a color para el modelo RGB se construye habitualmente sobre la matriz de fotodetectores usando el *filtro (o mosaico) de Bayer*, figura 3.10.

El mosaico de Bayer está formado por un 50 % de filtros verdes, un 25 % de rojos

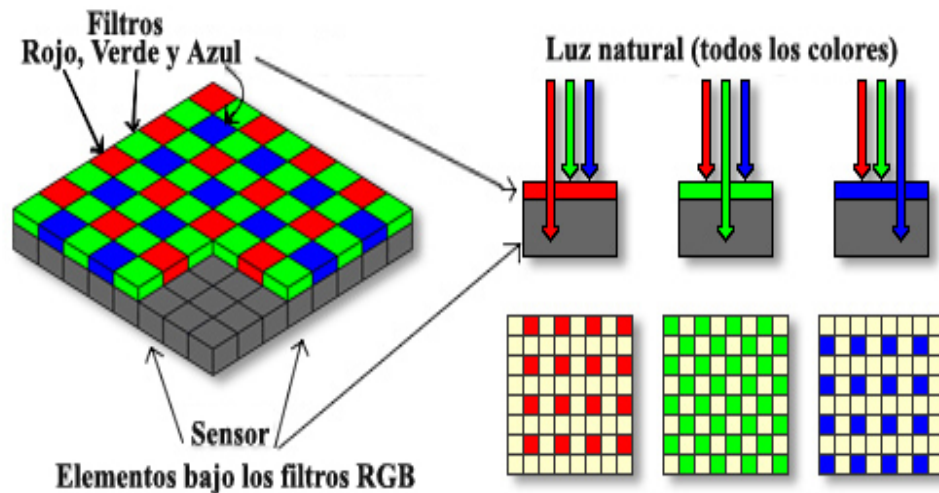


Figura 3.10: El filtro de Bayer

y un 25 % de azules. Mezclando información de dos muestras verdes, una roja, y una azul se obtiene el valor de color del píxel, que luego puede transformarse a un modelo de color conocido, como RGB, mediante técnicas de interpolación por proximidad. La razón de que se use mayor cantidad de filtros verdes es que el ojo humano es más sensible a ese color que al resto, por lo que de este modo las imágenes creadas serán más “realistas”. En la figura 3.11 pueden apreciarse las diferencias en percepción de colores entre el ojo humano y los sensores de las cámaras. Obsérvese la limitación del ojo humano en lo que respecta a las longitudes de onda superiores a los 700 nm.

En la figura 3.12 se resume el proceso de adquisición y formación de una imagen digital.

3.2.3. Procesamiento

Son dos las formas principales en las que puede analizarse una imagen: directamente, analizando y operando sobre la matriz de píxeles (dominio espacial), o transformando primero la imagen mediante el uso de algún filtro y analizando posteriormente el resultado de dicha transformación. Los filtros más usados son los de frecuencia espacial,

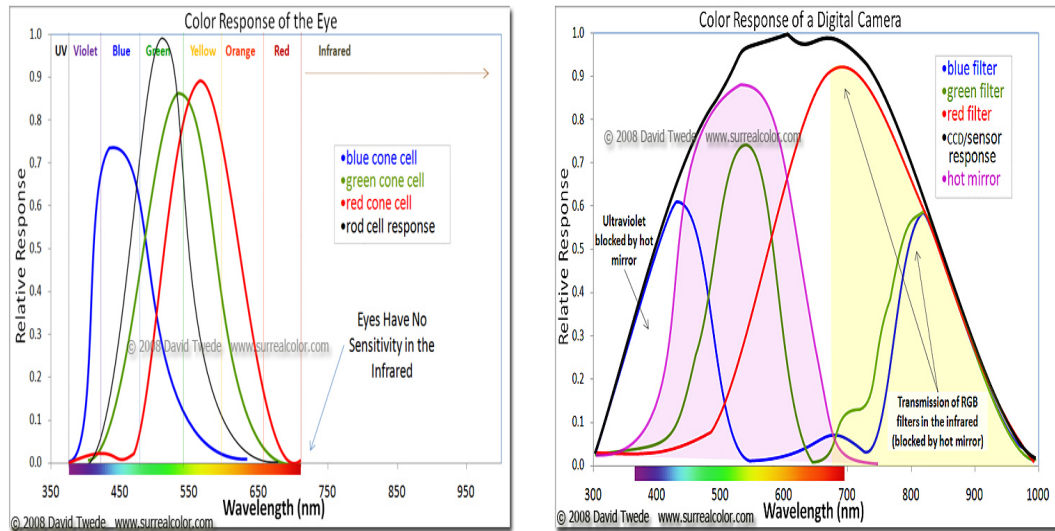


Figura 3.11: Comparación de la percepción de los distintos colores del ojo humano frente a las cámaras. Para lograr imágenes “realistas” la medida de los sensores debe de ajustarse al máximo a la percepción del ojo humano (Surrealcolor, 2009)

que permiten estudiar la imagen en el dominio de la frecuencia, especialmente útil para detectar cambios bruscos en la imagen (bordes), o elementos que se repiten siguiendo algún tipo de patrón (ruido, degradación, texturas).

A pesar de la inmensa variedad de técnicas existentes, en términos generales el tratamiento de imágenes suele dividirse atendiendo al grado de dificultad: bajo nivel, nivel medio y alto nivel.

Procesamiento de bajo nivel

Las técnicas de este nivel se conocen habitualmente como técnicas de *preprocesamiento*, donde el objetivo es mejorar la imagen y prepararla para el procesamiento en sí.

Las técnicas de mejora de una imagen suelen cambiar características globales de la imagen con vistas a mejorar su aspecto. Algunos ejemplos son: la corrección del brillo, el ajuste de los niveles de color, el ajuste del tono, la saturación y el contraste.




Figura 3.12: Adquisición y formación de una imagen digital. La luz emitida por los objetos de la escena incide en la óptica de la cámara, que la dirige a la zona fotosensible del sensor. Primero, la radiación infrarroja es filtrada mediante un filtro bloqueante (HM). Luego, se sitúa un mosaico de filtros de colores sobre la matriz de fotodetectores, para que sean sensibles sólo dentro de ciertos rangos. A partir de los valores de intensidad percibidos por cada fotodetector dentro del rango de colores filtrado, se asocia a cada uno de ellos valores de rojo, verde y azul, formando así cada píxel de la imagen

También son muy importantes las técnicas de reparación y mejora de errores concretos en la imagen, capaces de eliminar posibles distorsiones producidas por una captura incorrecta (eliminación del *ruido* de la imagen) o reparar una imagen degradada. En este contexto son de gran importancia las técnicas de procesamiento en el dominio de la *frecuencia*, ya que estudiando la frecuencia espacial se puede detectar la presencia de ruidos periódicos o de procesos de degradado. Otras técnicas de realce mejoran el aspecto de la imagen mediante operaciones de suavizado y promediado de los niveles de intensidad de los píxeles.

Por último, dentro de este nivel también entran técnicas de transformación geométrica de la imagen, que, mediante un estudio de la óptica utilizada por la cámara y el método de adquisición de la imagen, pueden corregir distorsiones geométricas o usarse para emparejar imágenes de la misma escena tomadas con distintos sensores o en distintos momentos (registro de imágenes). En algunos casos el registro de imágenes es tan complejo que las técnicas desarrolladas se consideran de un nivel superior.

Procesamiento de nivel medio

En este nivel se sitúan la inmensa mayoría de las técnicas de VA, y puede considerarse como el único nivel “obligatorio”, pueden no aplicarse técnicas de bajo nivel o alto nivel pero siempre se suele utilizar alguna técnica de nivel medio. Las operaciones dentro de este nivel pueden separarse en tres categorías: *segmentación*, *descripción* y *reconocimiento*.

La primera (segmentación), es la formada por todas aquellas técnicas orientadas a separar la imagen en partes de mayor o menor interés según distintas características, para luego analizar cada una por separado. Pueden verse como técnicas de clasificación, donde se etiqueta cada parte de la imagen en distintas clases. Las partes pueden ser sólo dos o varias, y representar todo tipo de elementos, desde distintas clases de niveles de gris hasta objetos. Algunas de las técnicas más usadas para la segmentación son las de umbralización (separación en dos clases según valores de intensidad), detección de bordes, crecimiento de regiones, así como segmentación por forma, textura, color, etc.

Las técnicas de descripción son aquellas orientadas a representar los elementos observados en la imagen, normalmente después de la segmentación. Dependiendo de los

3.2. Fundamentos de la Visión Artificial

elementos analizados, éstos pueden caracterizarse de formas muy variadas, por ejemplo por su forma geométrica, por su tamaño, su color, su textura, etc.

Un paso más allá de la descripción de los elementos observados es su reconocimiento como objeto o patrón conocido. Es decir, ser capaces de determinar, a partir de las descripciones obtenidas de cada parte o elemento de interés de la imagen, si pertenecen a algún objeto o patrón conocido a priori. Este tipo de procesamiento se sitúa en el límite entre el nivel medio y el alto, como se explica en el siguiente apartado.

Procesamiento de alto nivel

Las técnicas de procesamiento de alto nivel están asociadas directamente a la interpretación y comprensión de la escena. Estas técnicas suelen estar fuertemente ligadas a métodos de IA, ya que para comprender algo se necesita inferir y razonar con información de la escena. El proceso de inferencia y razonamiento se puede realizar con o sin conocimiento del dominio.

En este nivel se sitúan todas las técnicas de reconstrucción de la escena o de toma de decisiones a partir de imágenes. Además de técnicas de IA también intervienen en muchos casos métodos de estadística o de geometría, como por ejemplo las técnicas geométricas que permiten reconocer un objeto desde cualquier ángulo.

Las técnicas de reconocimiento vistas en el nivel medio, pueden considerarse de alto nivel cuando el conocimiento a priori usado sobre los elementos a reconocer utiliza una base de conocimiento sobre las características del objeto que va más allá de una pura descripción sencilla del tipo “es redondo” o “es verde”.

La figura 3.13 muestra un procesamiento clásico sobre una imagen para el reconocimiento e identificación de distintos objetos por su forma y color. Efectuando tareas de realce (bajo nivel), segmentación y descripción por color y forma (nivel medio) y reconocimiento de alto nivel, se puede llegar a identificar los objetos de cada clase que hay en la imagen, en este caso pimientos naranjas, amarillos y rojos.

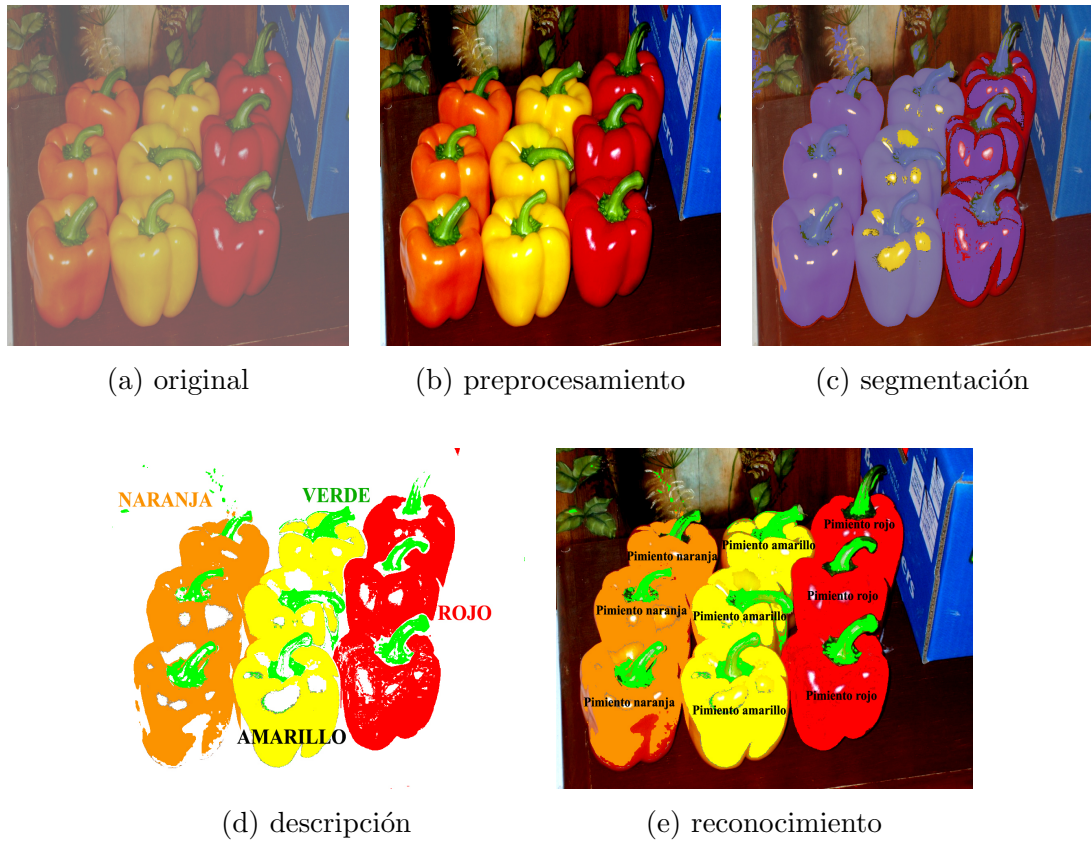


Figura 3.13: Reconocimiento e identificación de objetos en una imagen. a) imagen original, b) se corrigen los niveles de brillo, contraste y color de la imagen original, c) los objetos se segmentan por su color, d) una vez segmentados, se describe cada elemento según el color, e) usando tanto la descripción basada en color como la información a priori de la forma de los pimientos (rabo verde rodeado de color), se puede reconocer cada pimiento por separado

3.3. Visión Artificial y agricultura

La VA está presente en todas las etapas de la AP, desde el sembrado hasta la post-recolección, pasando por la irrigación, aplicación de tratamientos, cosecha o monitorización de los factores ambientales (Rodríguez-Díaz y Berenguel-Soria, 2004).

En esta sección se verán brevemente algunos ejemplos de aplicaciones de la VA

3.3. Visión Artificial y agricultura

en AP, dejando de lado el muestreo de malas hierbas, objeto central de esta tesis y estudiado con más detalle en la sección 3.4.

Sembrado: Durante el sembrado, la VA puede aplicarse para monitorizar desde la sembradora el número de errores de sembrado producidos (Norremark et al., 2007), o para hacer un mapa de sembrado que ayude a estimar donde crecerá el cultivo (Kaizu y Imou, 2008; Leemans y Destain, 2007).

La VA puede también usarse en semilleros para controlar la calidad de la germinación de las semillas, como es el caso de Ureña et al. (2001), donde se presenta un sistema que da un valor de la cantidad y calidad de las semillas usando una cámara convencional y lógica borrosa, figura 3.14 o el caso de Huang (2007), donde se analizan las imágenes para detectar a tiempo enfermedades que ataquen a las semillas.

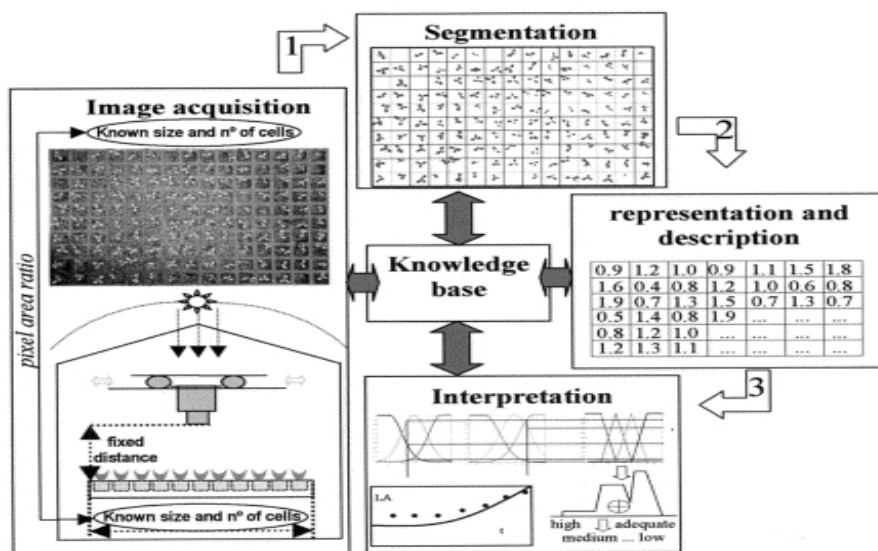


Figura 3.14: Mediante la toma de imágenes de semilleros, puede estimarse el tamaño de las plántulas. Además, por su forma y orientación puede incluso valorarse la calidad (Ureña et al., 2001)


Monitorización : Mediante VA puede llevarse a cabo cualquier tipo de monitorización y de medidas no destructivas de un cultivo. Puede monitorizarse el estado del suelo, el correcto uso del agua y demás nutrientes, el rendimiento de la cosecha (Dunn

et al., 2006), e incluso seguir el crecimiento de las plantas y hortalizas para asegurar que las condiciones bajo las que están desarrollándose son las adecuadas (Van Henten y Bontsema, 1995), o para detectar enfermedades a tiempo (Boissard et al., 2008).


Recolección robotizada y guiado autónomo de tractores : Uno de los procesos más robotizados dentro de la agricultura es el de la cosecha y recolección, especialmente en invernaderos, existiendo robots dotados de VA para localizar las hortalizas a recoger (García~Pérez, 2004; Rodríguez-Díaz y Berenguel-Soria, 2004). Entre ellos destacan los robots recolectores de pepinos, uvas y fresas desarrollados en la universidad de Okayama en Japón (LASE, 2005). Un ejemplo de sistema de VA usando una cámara convencional y un sensor de rango para la localización de frutos puede verse en Jiménez et al. (1999), figura 3.15.



(a) imagen convencional



(b) imagen de distancias
(sensor de rango)



(c) combinando ambas imágenes
se resaltan los frutos



(d) los frutos son fácilmente
localizables

Figura 3.15: Procesamiento de imágenes para la recolección automática de frutas (Jiménez et al., 1999)

3.3. Visión Artificial y agricultura

A todo lo anterior hay que añadir el papel relevante de la VA en el guiado autónomo de tractores (Keihcer y Seufert, 2000; Reid et al., 2000; Torii, 2000). Habitualmente, el cultivo se siembra en líneas, creciendo éste de forma ordenada y consecutiva. Este hecho puede aprovecharse para guiar tractores y demás vehículos que deban recorrer el campo.

El enfoque usado varía dependiendo del tipo de cultivo, la orientación de la cámara y la precisión requerida. Sin embargo, prácticamente todos los trabajos en este contexto detectan las líneas de cultivo aprovechando su geometría (figura 3.16), y posteriormente aproximan las líneas detectadas mediante ecuaciones, para extraer la dirección y poder guiar el tractor.

Los métodos de VA usados para la detección de las líneas de cultivo pueden dividirse en dos categorías. En los primeros, las imágenes se toman enfocando la cámara directamente hacia el suelo, de modo que las líneas de cultivo aparecen como columnas verticales en la imagen. Posteriormente, basta con mirar en qué columnas de la imagen hay mayor número de píxeles verdes, siendo dichas columnas las que corresponden al cultivo, figura 3.16 (Hague y Tillet, 2001; Olsen, 1995; Ribeiro et al., 2005; Sogaard y Olsen, 2003).

La segunda categoría utiliza imágenes tomadas enfocando la cámara hacia el horizonte, por lo que las líneas de cultivo se ven en perspectiva. El procesamiento en estos casos es algo más complicado, y suelen usarse técnicas de transformación de la perspectiva combinadas con técnicas de detección de líneas en imágenes como la transformada de Hough (Gonzalez y Woods, 2003). Sin embargo, merece la pena el esfuerzo suplementario ya que usando estas imágenes se cubre una mayor porción del terreno y por lo tanto la detección de las líneas no es tan vulnerable a cambios locales como errores de sembrado, aparición de rodales de malas hierbas pegados al cultivo, etc. (Bakker et al., 2008; Billingsley y Schoenfisch, 1997; Leemans y Destain, 2006; Tellaeche et al., 2008b; Tillet y Hague, 1999).

Post recolección (clasificación) : Tal como se vio en el ejemplo de la figura 3.13, durante la post recolección pueden usarse técnicas de VA para la clasificación del producto recogido, según distintos tamaños, color, calidad o incluso para distinguir entre distintos tipos de productos.




Figura 3.16: Ejemplos de métodos de guiado de tractores mediante VA

Las mayores dificultades a la hora de aplicar VA en la agricultura surgen de la gran variabilidad encontrada en un campo y de que la mayoría de las tareas se realizan en exteriores y, por tanto, con iluminación no controlada.

Dependiendo de la meteorología, contaminación, plagas y demás factores ambientales, el mismo campo puede presentar características muy distintas en diferentes épocas del año. La figura 3.17 muestra un ejemplo de dos imágenes tomadas en el mismo campo de caña de azúcar en Australia en dos meses distintos, ambos en fecha de tratamientos. En agosto, (invierno austral), las plantas sufren el frío y la falta de lluvias, volviéndose de color casi púrpura, mientras que en diciembre (verano y época de lluvias), el cultivo prospera, sano y fuerte, mostrando un fuerte color verde. Esta variabilidad no es sólo estacional sino que también es espacial, tal y como se explicó en el Capítulo 2, pudiendo encontrar una enorme diversidad de condiciones dentro del mismo campo en el mismo instante de tiempo.

A todo lo anterior hay que añadir la dificultad de trabajar en exteriores, donde al no tener control sobre la meteorología pueden producirse variaciones drásticas de iluminación que cambian radicalmente la calidad de las imágenes, u otros fenómenos inesperados (viento, lluvia, etc.) que interfieren con el entorno de trabajo llegando a impedir la realización de las tareas agrícolas y por ende la toma de imágenes.

3.3. Visión Artificial y agricultura




Figura 3.17: Variabilidad de condiciones en el campo. Imágenes tomadas en el mismo campo en Bundaberg, Australia

Es deseable diseñar sistemas que sean robustos ante todos estos cambios, ya que de lo contrario es muy probable que el sistema sólo funcione bien bajo unas circunstancias determinadas, o que sea necesario recalibrarlo cada vez que se produce algún cambio en el entorno, lo que puede suceder varias veces en un mismo día o en zonas distintas del campo.

La problemática de la VA en exteriores es algo muy estudiado, existiendo varios métodos de aprendizaje y clasificación para ayudar en la segmentación y para eliminar el efecto de las sombras y cambios de iluminación sobre las imágenes (Arbeláez y Cohen, 2006; Bosch et al., 2007; Finlayson et al., 2002; Manduchi, 2006). Aún así, sigue siendo en la actualidad uno de los mayores problemas de la VA, de manera que en cada trabajo la problemática asociada a la iluminación se resuelve de modo distinto. Esto conduce en muchos casos a la adquisición de la imagen con iluminación controlada mediante el uso de sombrillas o de luz artificial.

3.4. Muestreo de malas hierbas mediante Visión Artificial

Como se vio en el Capítulo 2, para llevar a cabo tratamientos selectivos de herbicida, es necesario efectuar un muestreo de las malas hierbas (detectar, cuantificar y localizar la posición de éstas). La VA puede ser usada para llevar a cabo cualquiera de los tres tipos de muestreo (discreto, continuo o remoto). El modo en que se ha efectuado la recolección de información sobre el campo mediante captura de imágenes ha dependido en gran medida de la tecnología disponible en cada momento, pudiéndose clasificar en tres grandes grupos (Thorp y Tian, 2004): 1) mediante dispositivos embarcados en aeronaves, 2) mediante dispositivos embarcados en satélites y 3) desde tierra. El grupo 1) y 2) también recibe, como se ha visto, el nombre de teledetección (*remote sensing* en inglés).

El uso de aeronaves para el muestreo de malas hierbas comenzó a principios de los años 90, cuando el procedimiento habitual era tomar fotografías en el infrarrojo cercano (NIR) desde aeronaves volando a baja altura y que un experto analizase las fotografías para generar el mapa de distribución de malas hierbas.

Desde entonces, se han producido importantes mejoras en la tecnología disponible, facilitando sensiblemente la tarea de adquisición y aumentando el rango de posibles aplicaciones de este tipo de sistemas. La aparición del uso civil de satélites, y de cámaras hiperespectrales y multiespectrales facilitan y potencian el reconocimiento de cada especie (Jurado-Expósito et al., 2003a; López-Granados et al., 2002).

Aún así, siguen presentando inconvenientes motivados por su alto coste y su baja precisión debida a la altura, que hace que cada píxel de la imagen represente aproximadamente un metro cuadrado de superficie, contrastando con la necesidad de tener información detallada de cada unidad de terreno. Además, el uso de satélites es todavía un servicio caro en el que es difícil definir, sin un incremento considerable en el coste del servicio, una ventana temporal de adquisición de un par de días, a lo que hay que sumar la clara desventaja de que las fotos deben ser tomadas en días despejados y que los satélites pasan pocas veces sobre la misma área. Todos los inconvenientes podrían solucionarse mediante el uso de aeronaves más pequeñas, no tripuladas, autónomas o teleredigidas por algún operario. Sin embargo, las aeronaves ligeras son más inestables y no pueden cargar con equipos pesados, además de ser de difícil manejo en condi-

3.4. Muestreo de malas hierbas mediante Visión Artificial

ciones meteorológicas adversas, representando sin embargo una alternativa mucho más económica y rápida que el uso de aviones.

Durante la última década, las técnicas de recogida de datos aéreos han sufrido un claro retroceso, dejando paso cada vez más a la detección desde tierra, que permiten alcanzar precisiones centimétricas. Dentro de este contexto, las técnicas de VA usando cámaras convencionales (espectro visible y NIR) han sido, desde sus inicios, los métodos más usados, debido a su bajo coste y gran precisión. Los trabajos en esta línea desarrollados hasta el momento toman las imágenes desde una altura generalmente inferior a tres metros, mediante el uso de trípodes, acoples a distintas máquinas (tractores, robots agrícolas, etc) o sencillamente a mano (Thorp y Tian, 2004).

Los trabajos para la detección de malas hierbas desde tierra son difíciles de clasificar y comparar debido fundamentalmente a las diferencias notables que presentan los distintos tipos de cultivos e infestaciones entre sí. Por ejemplo, el procesamiento llevado a cabo para la detección de malas hierbas en huertas o invernaderos con cultivos de coles es radicalmente distinto al realizado en grandes explotaciones, como por ejemplo cereales de invierno o el maíz, donde la zona a explorar es mucho más extensa y la iluminación es difícilmente controlable. Además, las condiciones de un mismo tipo de cultivo varían mucho también de unas zonas a otras.

Sin embargo, todos los trabajos tienen en común el primer paso: la segmentación de la capa vegetal (plantas) con respecto al resto de elementos que aparecen en la imagen (suelo, paja, rocas, etc.). Los procedimientos de segmentación de la capa vegetal suelen tener en cuenta que todo píxel asociado a vegetación mostrará una clara predominancia del color verde sobre los demás colores. Sin embargo, debido a las diferencias mostradas por cada cultivo, así como a las dificultades añadidas de trabajar en exteriores, la tarea de segmentación resulta más compleja de lo que inicialmente cabría esperar .

Como prácticamente todas las cámaras actuales usan el espacio de color RGB para la representación de cada píxel, la segmentación puede llevarse a cabo directamente analizando los valores de verde, como es el caso de (Yang et al., 2003), donde simplemente se considera parte de la vegetación todo píxel cuya intensidad en el plano representando el color verde sea mayor que un cierto umbral. Del mismo modo, en Aitkenhead et al. (2003) se usa la proporción de verde $G/(R + G + B)$, combinado con el valor de un cierto umbral determinado mediante prueba y error.

En Woebbecke et al. (1995) se presenta un índice cromático para la discriminación de plantas que da buenos resultados, y que es usado en numerosos trabajos. El índice cromático se obtiene mediante una combinación lineal de los planos de color RGB con constantes $r = -1, g = 2, b = -1$, figura 3.18.




Figura 3.18: Segmentación de vegetación en imágenes pertenecientes a distintos tipos de cultivo (caña de azúcar, cereal y lechuga) usando como constantes asociadas a la combinación lineal $r = -1, g = 2, b = -1$ (Woebbecke et al., 1995)

Otros índices cromáticos con resultados satisfactorios son el *exceso de verde*, que define como vegetación aquellos píxeles cuya diferencia entre la componente roja y la componente verde $G - R$ es suficientemente grande o la combinación lineal propuesta en Ribeiro et al. (2005), con constantes $r = -0,7, g = 0,588, b = 0,136$.

En Pérez et al. (2000) se propone un índice parecido al *exceso de verde*, aunque ponderado sobre la intensidad total: $G - R / G + R$. En Meyer y Neto (2008); Van Evert et al. (2006) se puede encontrar una comparativa de todos los índices cromáticos.

Algunas técnicas de segmentación van mucho más allá, intentando adaptar la segmentación a cada imagen, para hacer frente a las diferencias en iluminación y demás condiciones variables que surgen al trabajar en exteriores. Este es el caso de Andreasen

3.4. Muestreo de malas hierbas mediante Visión Artificial

et al. (1997), donde a partir del estudio del histograma de la componente verde, se determina el mejor índice a usar en cada imagen y se establece el umbral a partir del cual se considera la intensidad de verde suficientemente grande. Más complicados aún son los algoritmos de segmentación propuestos en Tian y Slaughter (1998) o Zheng et al. (2009), que usan procesos de Aprendizaje Automático para aprender cuál es la mejor forma de segmentar cada imagen, o el propuesto en Onyango y Marchant (2003), que no sólo usa información de color sino que también utiliza información a priori sobre la forma de las plantas.

Aunque la mayoría de los trabajos usan directamente los planos RGB, algunos proponen la utilización del modelo HSI, Matiz-Saturación-Intensidad o Hue-Saturation-Intensity en terminología inglesa, que ofrece la ventaja de separar el color de la intensidad, siendo más robusto ante cambios de iluminación. Una vez transformada la imagen RGB original al modelo HSI, puede segmentarse directamente la imagen aplicando una umbralización sobre las intensidades en el plano de matiz (Gottschalk et al., 2008), algún algoritmo de clasificación de colores basado en los planos de matiz y saturación, como redes Bayesianas (Hemming y Rath, 2001; Lee et al., 1996, 1999) o por simple comparación con valores de matiz y saturación etiquetados en imágenes anteriores como vegetación (Blasco et al., 2002).

Por último, en algunos cultivos también puede combinarse la información en el espectro visible con un sensor de infrarrojos para la detección (Gerhards y Christensen, 2003).

Una vez que la vegetación ha quedado separada del resto de componentes de la imagen, se deben detectar los píxeles que representan malas hierbas. La detección de malas hierbas puede llevarse a cabo usando información sobre el color, posición, forma, textura o tamaño, según el tipo de cultivo, las especies de malas hierbas estudiadas, el modo en el que las imágenes son tomadas, la precisión deseada y las condiciones bajo las cuales se lleva a cabo la experimentación (Slaughter et al., 2008). Un ejemplo de esta gran variedad de condiciones puede verse en la figura 3.19.

En cultivos de lechuga, las plantas y las malas hierbas se diferencian claramente por el tamaño y la separación, ya que las lechugas son mucho más grandes que las malas hierbas, además de estar plantadas con bastante separación, figura 3.19(e) (Blasco et al., 2002). Algo parecido ocurre en cultivos de coliflores, donde a partir de simplemente

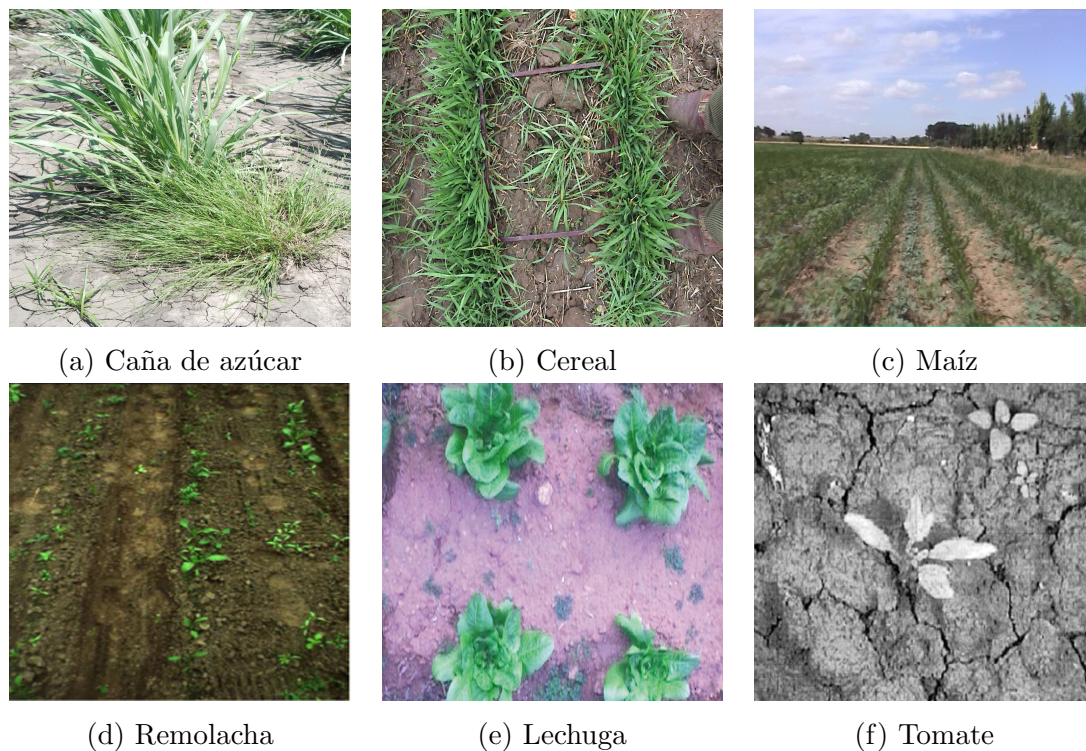


Figura 3.19: Distintas imágenes mostrando distintos cultivos y especies de malas hierbas

la posición de las plantas y unas cuantas características de forma puede discriminarse con éxito entre coliflores y malas hierbas (Onyango y Marchant, 2003). En cultivos de repollo y zanahoria, las malas hierbas tienen un color y tamaño muy distinto al del propio cultivo y por lo tanto pueden ser separadas de éste mediante métodos de clasificación por colores y tamaño (Hemming y Rath, 2001).

Analizando el espectro de cada especie, a veces se puede discriminar entre malas hierbas y cultivo usando cámaras NIR. En campos de trigo, la especie de malas hierbas *Bidens pilosa* puede discriminarse directamente por su respuesta en el NIR y alguna característica de forma (Zhang et al., 2008). En Gerhards y Christensen (2003); Gerhards y Oebel (2006), combinando la cámara convencional con una cámara NIR efectúan la discriminación entre malas hierbas y cultivo sobre campos de remolacha, cereal de verano, y maíz por diferencias en su espectro con resultados satisfactorios. En Piron et al. (2008) logran discriminar entre malas hierbas y cultivo en zanahoria usando tres

3.4. Muestreo de malas hierbas mediante Visión Artificial

bandas distintas del espectro.

Estos son ejemplos que muestran cómo la detección de malas hierbas en la mayoría de los casos es un proceso complejo que depende del cultivo y el tipo de mala hierba que se desea detectar y por tanto las técnicas son difícilmente generalizables.

En la mayoría de los cultivos, sin embargo, la detección de malas hierbas no es tan directa. En muchos casos, el color y aspecto de las malas hierbas es muy parecido al del cultivo, y pueden incluso encontrarse mezcladas distintas especies, cada una de las cuales tiene características distintas. En estos casos, la detección debe llevarse a cabo usando métodos más complejos.

Utilizando conocimiento experto sobre las malas hierbas presentes en el campo, se puede construir un modelo estadístico de las mismas, y definir una serie de características que pueden usarse para su discriminación, incluyendo tantas características como sea necesario (Andreasen et al., 1997; Van Evert et al., 2006).

Disponiendo de imágenes de entrenamiento y conociendo de antemano qué especies de malas hierbas pueden encontrarse en el cultivo, es posible extraer las características que permitan detectar las malas hierbas de forma automática. Para efectuar dicha extracción de características, muchos trabajos utilizan redes bayesianas, capaces de relacionar variables aleatorias entre sí (Granitto et al., 2005; Lee et al., 1996, 1999; Pérez et al., 2000).

De modo similar, se pueden usar redes neuronales (Aitkenhead et al., 2003; Astrand y Baerveldt, 2002; Burks et al., 2005; Yang et al., 2002a,b), o wavelets (Bossu et al., 2009; Chou et al., 2007; Ishak et al., 2009; Tang et al., 1999; Tian et al., 1999). El problema de estas técnicas es que sólo sirven para discriminar entre distintas especies de cultivo y malas hierbas en imágenes en las que sólo se muestra una especie a la vez, véase la figura 3.20. Esto implica que para efectuar un muestreo de malas hierbas o bien se toman imágenes de cada especie por separado, como en Yang et al. (2003), o bien se debe clasificar primero la imagen por zonas en función de las plantas que aparecen (Bossu et al., 2009; Tang et al., 1999; Tian et al., 1999). El problema de este enfoque es que no puede resolver adecuadamente el caso real en el que las imágenes presentan oclusiones de varias especies o de cultivo con infestación.

En campos abiertos y de gran separación entre líneas de cultivo, donde las malas




Figura 3.20: Mediante redes neuronales y wavelets se puede efectuar una discriminación de tipos de cultivo y/o mala hierba, siempre y cuando en cada imagen sólo aparezca una única especie (Chou et al., 2007)

hierbas crecen entre líneas pero tienen características muy similares al cultivo, puede extraerse primero el cultivo, de modo similar a los sistemas de guiado autónomo de tractores, y posteriormente detectar como mala hierba todos los píxeles de vegetación restantes (Hague et al., 2006; Ribeiro et al., 2005; Tellaeche et al., 2008a).

Desgraciadamente, ninguno de estos trabajos ha dado lugar a una transferencia tecnológica real (Stafford, 2000). Ciertos métodos, aunque funcionan bien, son demasiado lentos para su uso directo en el campo, o utilizan equipos demasiado caros para que su uso sea rentable, mientras que otros parten de condiciones irreales de iluminación o de estado de crecimiento de cultivo y cantidad de malas hierbas. Sin lugar a duda, desde sus comienzos, la detección automática de malas hierbas ha sido una tarea desalentadora, dada la gran cantidad de variables a tener en cuenta y la dificultad de adaptar las técnicas a la realidad. Aún así, algunos de los trabajos demuestran el potencial de la VA aplicada a la AP, y permiten vislumbrar que la aplicación real de dichas técnicas no está lejos.

El trabajo de investigación presentado en esta tesis pretende mejorar los resultados de las técnicas comentadas, desarrollando métodos de percepción basados en VA para la detección de malas hierbas ante una amplia variedad de situaciones reales, tratando de conseguir procesos de detección en tiempo real adaptados a equipos lo más baratos

3.4. Muestreo de malas hierbas mediante Visión Artificial

posibles, garantizando así su viabilidad. El punto de partida para los experimentos son las numerosas imágenes y vídeos captados a lo largo de los últimos cuatro años en varios campos de distinto tipo de cultivo tanto en España como en Australia.

Parte II

Sistema autónomo de aplicación de herbicida

Capítulo 4

Estimación de la cobertura de malas hierbas en muestreos fotográficos

Es la teoría la que decide lo que podemos observar

Albert Einstein

El objetivo principal en este capítulo es el diseño y desarrollo de métodos de VA que permitan estimar la cobertura de mala hierba a partir de imágenes asociadas a puntos de muestreo, para posteriormente generar los mapas de tratamiento. Dichos métodos deben ser capaces de procesar de forma completamente automática cada una de las imágenes muestreadas, suministrando una estimación real y objetiva. Asimismo, las aproximaciones que se propongan deben ser capaces de proporcionar una valoración del estado de crecimiento del cultivo, parámetro importante a la hora de decidir la cantidad de tratamiento a aplicar, ya que el grado de amenaza de una infestación depende del nivel de desarrollo del cultivo.

El muestreo de partida da lugar a un conjunto de fotografías tomadas en distintos puntos del campo de cultivo que se quiere evaluar. Las imágenes se toman mediante una cámara digital colocada en un trípode y con un ángulo cenital. Los puntos de muestreo, ajustados o no a una malla, se geo-referencian con la ayuda de un GPS (Global Positioning System). Los métodos propuestos en este capítulo se prueban en imágenes de cultivos de cereal de invierno y maíz, donde las líneas de cultivo presentan separación entre sí. Todas las imágenes usadas para este trabajo han sido tomadas con cámaras convencionales con una óptica de calidad media-alta (Nikon Coolpix 5700 de 5 Mp, Nikon D60 de 10Mp y Nikon D80 de 10 Mp) en varios campos de la zona sureste de Madrid (Arganda del Rey) por personal del Centro de Ciencias Medioambientales y del Instituto de Automática Industrial, centros pertenecientes al CSIC. Los muestreos han sido llevados a cabo durante distintos días de los últimos cuatro años, siempre en los meses de febrero-marzo (cereal) y Mayo (maíz), fechas habituales para la aplicación de tratamientos de post-emergencia.

Las malas hierbas objeto de este estudio son *Avena sterilis* y *Papaver rhoeas* en cereal de invierno y *Sorghum*, *Cyperus*, *Xanthium* y *Datura* en maíz. Algunas de estas infestaciones, como la *Avena sterilis* y la *Papaver rhoeas*, se caracterizan por ser indistinguibles del cultivo, tanto en forma como en sus componentes espectrales RGB (color), en el momento en el que deben ser aplicados los tratamientos. Esta característica imposibilita reconocer la infestación por su naturaleza mediante el uso de técnicas de reconocimiento de patrones (Gonzalez y Woods, 2003; Perner, 2006) o de clasificación de texturas naturales (Pajares y de la Cruz, 2002), obligando a buscar otras estrategias de discriminación. Un buen criterio para diferenciar el cultivo de las malas hierbas podría ser la posición, es decir, considerar como infestación todo aquello que crezca fuera de las líneas de cultivo. Así el problema se traduce en localizar, y separar del resto de la imagen, las líneas de cultivo y contabilizar como mala hierba toda la cubierta vegetal que queda entre las mismas. Esta estrategia es compatible con la forma de realizar la aplicación de herbicida, que como veremos en capítulos posteriores es mediante la activación independiente de segmentos de pulverización en una barra de aplicación de tratamientos, ya que las especies de malas hierbas consideradas tienen un patrón de crecimiento agregado, es decir, crecen en forma de rodales, figura 4.1. El crecimiento en forma de rodales asegura también que los valores de densidad de mala hierba observados entre líneas puedan ser extrapolados para dar una medida correcta

de la cantidad de mala hierba presente sobre el cultivo (donde las malas hierbas son imposibles de distinguir).



Figura 4.1: *Las infestaciones encontradas crecen en forma de rodales*

En los muestreos llevados a cabo, las fotos se tomaron siempre con la misma distancia focal y colocando la cámara verticalmente de forma que quedase recogido el espacio entre dos líneas de cultivo consecutivas, tal y como se muestra en la figura 4.2. De esta forma se obtiene una vista cenital de dos líneas consecutivas de cultivo y el área entremedias. Desde esta perspectiva las líneas de cultivo tomarán una forma geométrica clara en las imágenes, de columnas verticales. El área cubierta por cada imagen es de aproximadamente $0,51m^2$ ($0,6m \times 0,85m$).

La base de datos actual contiene 1552 imágenes, con variabilidad tanto espacial como temporal en la adquisición, asegurando por lo tanto la representación de gran diversidad de situaciones, tanto de iluminación (días soleados o nublados) y textura del suelo (suelo seco o húmedo), como de estado de crecimiento del cultivo o de cantidad y posición de malas hierbas. Ejemplos de esta diversidad presente en las imágenes se muestran en la figura 4.3.

Se ve claramente cómo en muchos casos el aspecto de las malas hierbas en el estado inicial de crecimiento (momento óptimo para aplicar el herbicida) es indistinguible del cultivo. Esto es especialmente fácil de apreciar en las imágenes 4.3(a) y 4.3(d) (cereal) y en las imágenes 4.3(j) y 4.3(o) (maíz).




Figura 4.2: Método de toma de las imágenes de muestreo

El problema de localizar, y separar del resto de la imagen las líneas de cultivo y contabilizar como mala hierba toda la cubierta vegetal que queda entre las líneas detectadas se simplifica gracias al método de toma de las imágenes. Pero aún así, la discriminación presenta varias dificultades. Por ejemplo, las figuras 4.3(d) y (j), muestran un caso en el que la mala hierba está unida al cultivo, complicando la discriminación automática. Existen otros casos, como los que se muestran en las figuras 4.3(e),(h),(k) y (p), en los que un error en el sembrado da lugar a líneas de cultivo discontinuas y/o con deformaciones que podrían dificultar el proceso de separación automática. En otros casos el problema radica en el nivel de crecimiento del cultivo. Por ejemplo, en la figura 4.3(b) las líneas son prácticamente inexistentes, mientras que en las figuras 4.3(f) y (g) debido al tamaño de las mismas no hay prácticamente espacio entre líneas. Incluso puede pasar, como se aprecia en la figura 4.3(c), que una línea de cultivo sea más grande que otra. Finalmente, en ciertas ocasiones un área del campo puede hallarse infestada de rodales de malas hierbas, como en las figuras 4.3(n) y (l). Problemas añadidos tienen que ver con el hecho de que al ser imágenes tomadas en exteriores, aparecen en ellas claras diferencias de iluminación, dependiendo de si el día era o no soleado, e incluso diferencias en el color del suelo según el grado de humedad, dependiente de las precipitaciones en la zona.

CEREAL



(a)



(b)



(c)



(d)



(e)



(f)



(g)



(h)

MAÍZ



(i)



(j)



(k)



(l)



(m)



(n)



(o)



(p)

Figura 4.3: Ejemplo de imágenes de entrada. Las imágenes de la (a) a la (h) corresponden a cereal y de la (i) a la (p) corresponden a maíz

Sin duda, el mayor reto es diseñar y desarrollar métodos capaces de discriminar correctamente entre cultivo, malas hierbas y suelo en todas las situaciones descritas.

Esto conduce a uno de los objetivos de la investigación: el diseño y desarrollo de métodos de visión artificial que sean capaces de discriminar correctamente entre cultivo, malas hierbas y suelo en imágenes tomadas en situaciones reales sin control de la iluminación.

Los métodos de visión artificial desarrollados se presentan en la sección 4.1 y fueron publicados en (Burgos-Artizzu et al., 2009c). Los procedimientos desarrollados se integraron en una plataforma de procesamiento de imágenes que en la actualidad ayuda en todo el proceso de construcción de mapas de índice de cobertura de malas hierbas y estado de crecimiento de cultivo para un campo a partir de imágenes de puntos de muestreo del mismo. Con vistas a optimizar el resultado de los métodos y facilitar el uso de la plataforma, se efectuó un ajuste de los parámetros del procesamiento mediante algoritmos evolutivos, explicado en la sección 4.2 y presentados en (Burgos-Artizzu et al., 2008). Finalmente, se dotó a la plataforma de un sistema de ayuda al procesamiento basado en experiencia, que indica al usuario cuál es la mejor forma de procesar una imagen en cada caso, sección 4.3, esta última aproximación y los resultados asociados se presentaron en (Burgos-Artizzu y Ribeiro, 2006) y se han publicado en (Burgos-Artizzu et al., 2009b).

4.1. Etapas y métodos del procesamiento de imágenes y plataforma de gestión de imágenes

Formalmente, a partir del tipo de imágenes descritas, el sistema de detección debe ser capaz de determinar los porcentajes de mala hierba, cultivo y suelo presentes en las fotografías. Los porcentajes de cultivo y suelo son importantes a la hora de medir el riesgo que supone para el cultivo la mala hierba detectada Ribeiro et al. (2005).

Una vez tomadas las imágenes, los objetivos del procesamiento se pueden desglosar en tres etapas, tal y como se muestra en la figura 4.4:

1. La correcta segmentación de vegetación frente al suelo y demás elementos presen-

4.1. Etapas y métodos del procesamiento de imágenes y plataforma de gestión de imágenes

tes en las imágenes. La imagen de entrada a color se transforma en una imagen binaria (sólo dos colores) donde los píxeles pertenecientes a la capa vegetal (cultivo y mala hierba) queden separados del resto (*etapa de segmentación*).

2. La detección y eliminación de las líneas del cultivo. Se detecta, contabiliza y elimina de entre los píxeles pertenecientes a la capa vegetal aquéllos que formen parte de alguna línea de cultivo (*etapa de detección o eliminación de líneas de cultivo*).
3. El filtrado y detección de píxeles asociados a malas hierbas una vez eliminadas las líneas de cultivo. Se determina y contabiliza qué píxeles de los restantes pertenecen a malas hierbas (*etapa de filtrado y extracción de malas hierbas*)

El procesamiento propuesto permite extraer, en cada una de las etapas, los porcentajes anteriormente enumerados: suelo en la segmentación, cultivo en la eliminación de las líneas de cultivo y mala hierba en el filtrado.

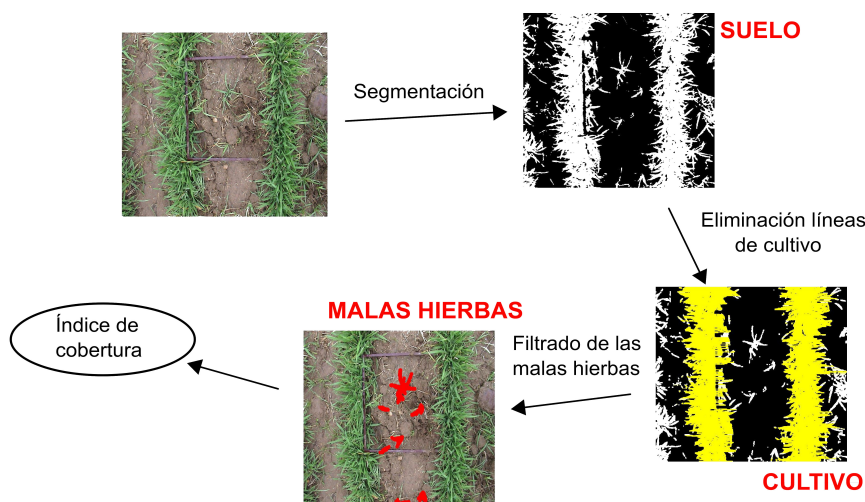


Figura 4.4: Etapas en el procesamiento de imágenes naturales

Si se analiza el banco de imágenes tomadas a lo largo de los cuatro últimos años, se puede observar que éstas muestran una gran variedad de situaciones, debido a las condiciones cambiantes en las que han sido tomadas, tanto de iluminación (difícilmente

controlable en exteriores) como de estado del suelo y de crecimiento de la capa vegetal. Por tanto, los métodos de procesamiento deberán ser capaces de adaptarse a todas las situaciones posibles. Además, a cada una de las tres etapas de procesamiento descritas le afecta de modo distinto los elementos cambiantes en la imagen. Por ejemplo, la iluminación (día soleado o nublado) y la humedad del suelo serán importantes para la obtención de una buena segmentación, teniendo que hacer frente a las sombras o reflejos presentes en la imagen para discriminar la capa vegetal del resto, mientras que serán características que no afectarán a ninguna de las siguientes etapas.

Para cada una de las tres fases de procesamiento se han desarrollado distintos métodos, que hacen frente al problema de múltiples maneras. Como se verá en lo que sigue, cada método presenta sus ventajas e inconvenientes dependiendo de las características de la imagen tratada. La plataforma desarrollada permite el cambio de método de procesamiento en cada etapa haciendo que éste sea más robusto y adaptable a la gran variedad de situaciones posibles.

A continuación se describen en detalle una por una las tres fases, enumerando los problemas encontrados, posibles soluciones y la aportación de este trabajo en cada una de ellas, mediante el diseño e implementación de distintos métodos.

4.1.1. Segmentación

La segmentación es el proceso por el cual se extraen de una imagen regiones de interés. Segmentar una imagen significa separar la imagen de partida en segmentos distinguibles, sobre los que posteriormente se operará por separado. En nuestro caso, se necesita diferenciar claramente qué zonas representan capa vegetal y cuáles no. En definitiva, de lo que se trata es de transformar la imagen de partida (planos de color Rojo-Verde-Azul, RGB) en una imagen binaria (blanco y negro), donde el blanco represente vegetación (cultivo y malas hierbas) y el negro represente fondo (suelo, sombras, piedras, etc.).

La segmentación es una de las operaciones más habituales en el procesamiento de imágenes. Su naturaleza (separar lo que se considera de interés, en cada caso, del resto), hace imposible su generalización, pudiéndose encontrar en la literatura un gran número de métodos de segmentación (Gonzalez y Woods, 2003; Pajares y de la Cruz,

4.1. Etapas y métodos del procesamiento de imágenes y plataforma de gestión de imágenes

2007) según el dominio del problema.

La segmentación sobre imágenes tomadas en exteriores, sin control sobre la iluminación, es un campo de investigación abierto en VA, pudiéndose encontrar métodos directos para la reducción o eliminación de los efectos indeseables, como por ejemplo el método para la eliminación de sombras planteado en Finlayson et al. (2002), o la segmentación mediante clasificación de colores (Arbeláez y Cohen, 2006). También es posible abordar la segmentación a través de técnicas de aprendizaje automático, como en Manduchi (2006), donde se propone un algoritmo que estima el tipo de iluminación presente comparándolo con imágenes previas y posteriormente ajusta los parámetros de la segmentación de acuerdo a dicha iluminación. En Tian y Slaughter (1998) se propone un algoritmo adaptativo para la clasificación de imágenes y su subsiguiente segmentación.

Los métodos de segmentación propuestos han sido diseñados teniendo en cuenta las ventajas de muchas de las técnicas ya existentes, pero buscando producir métodos simples y robustos, cuya adaptabilidad a distintas situaciones se logra por medio del uso de parámetros de entrada. Para cubrir todas las posibles situaciones que aparecen en las imágenes, se han desarrollado dos métodos: **S1** y **S2**.

Método S1 (Escala de grises + umbral)

El primer paso de **S1** consiste en transformar la imagen original a una imagen en escala de grises usando las propiedades del plano de color secundario o de pigmentación Cian en un modelo de color CMYK, usado en las impresoras. El plano Cian puede usarse en imágenes naturales para resaltar las partes de cubierta vegetal del resto (Ribeiro et al., 2005). Cian es el opuesto al rojo, lo que significa que actúa como un filtro y absorbe este color ($-R + G + B$). La cantidad de cian aplicada a un papel controlará la cantidad de rojo que se mostrará en la impresión. Magenta es el opuesto al verde ($+R - G + B$) y amarillo el opuesto al azul ($+R + G - B$). Al modo CMY se le añade el canal negro (Black) debido a que el negro generado por la mezcla de colores sustractivos, no es tan denso como el color negro puro. De este modo en el plano Cian del espacio CMYK han desaparecido, o se han atenuado, las sombras y los elementos con contenido rojo como puede ser el suelo. Así, al pasar la imagen original RGB a

una imagen CYMK, el plano de pigmentación Cian muestra una imagen en escala de grises donde las zonas de cubierta vegetal tienen mayor intensidad que el resto. Ahora bien, la transformación de RGB a CYMK no es directa y está normalmente basada en las características del dispositivo de salida (impresora). En definitiva, CMYK es un espacio de colores sustractivos o una gama entera de espacios de color ya que las tintas pueden variar y el efecto de las tintas depende del tipo de papel empleado, razón por la que hay que calibrar el dispositivo de salida.

Basándonos en la discriminación apreciada en el plano Cian, se puede construir una imagen en escala de grises que incremente la separación de la capa vegetal del resto mediante una combinación lineal de los planos de color primarios RGB con coeficientes r, g, b , siguiendo la ecuación 4.1 para todo píxel (x, y) de la imagen.

$$F(x, y) = r * R(x, y) + g * G(x, y) + b * B(x, y) \quad (4.1)$$

Los coeficientes de la combinación lineal o parámetros que es necesario ajustar para obtener el efecto deseado (r, g, b) , deben cumplir los requisitos mostrados en las relaciones dadas en la ecuación 4.2. La primera condición (que la suma de los valores de los tres coeficientes sea igual a 0) se impone para asegurar que los valores devueltos por la combinación lineal se mantengan en el mismo rango que los valores de entrada (en este caso $[0, 255]$ por tratarse de imágenes de 8 bits). Si no se respeta esta condición, es necesario aplicar algún metodo de reescalado de los valores de salida. Los siguientes requisitos incorporan la exigencia de que siempre exista una contribución del plano verde y ésta sea al menos igual que la del plano de color rojo. Finalmente, el último requisito tiene el propósito de limitar los posibles valores de los parámetros dentro de unos intervalos pequeños para facilitar los cálculos.

$$\left\{ \begin{array}{l} r + g + b = 0 \\ g \geq r \\ g \geq 0,5 \\ -3 \leq r \leq 1,5 \end{array} \right. \quad (4.2)$$

4.1. Etapas y métodos del procesamiento de imágenes y plataforma de gestión de imágenes


La elección de los parámetros juega un papel fundamental. Uno de los conjuntos de valores más usados es $r = -1, g = 2, b = -1$ (Woebbecke et al., 1995). Otros valores que han demostrado dar muy buenos resultados son los propuestos en (Ribeiro et al., 2005): $r = -0,7, g = 0,588, b = 0,136$. En la figura 4.5 se muestra el resultado de la combinación lineal usando ambos conjuntos de valores para los parámetros, mostrando cómo distintos valores para los coeficientes (r, g, b) dan lugar a resultados muy diferentes.



imagen de partida



(a) $r = -0,7, g = 0,588, b = 0,136$



(b) $r = -1, g = 2, b = -1$

Figura 4.5: Ejemplo de construcción de una imagen en escala de grises a partir de la combinación lineal de los planos RGB. Resultados para distintos valores de los coeficientes de combinación lineal

El segundo y último paso de **S1** consiste en obtener una imagen binaria aplicando un método de umbral clásico sobre la imagen en escala de grises anterior. Todos los

píxeles de la imagen que superen un cierto umbral se ponen al máximo valor (255, blanco), y el resto al mínimo valor (0, negro). En resumen, dada una imagen de partida H y un umbral T , se crea una imagen F tal que (ecuación 4.3):

$$F(x, y) = \begin{cases} 255 & \text{si } H(x, y) > T \\ 0 & \text{si } H(x, y) \leq T \end{cases} \quad (4.3)$$

En la figura 4.6 se puede observar el resultado con dos umbrales distintos, partiendo de la imagen de la figura 4.5(b). Se aprecia claramente cómo el valor del umbral influye de manera directa en la calidad de la imagen resultante. Un umbral demasiado bajo hace que se pierda información relevante, mientras que un umbral demasiado alto podría dar lugar a una imagen con ruido. El valor adecuado del umbral estará vinculado a la iluminación de la escena. Una iluminación de un día soleado hará que la intensidad media de los píxeles de la imagen sea mucho mayor que la de un día nublado, y por lo tanto el umbral óptimo también deberá ser mayor en un caso que en otro.

Método S2 (Plano RGB)

En este método, la segmentación se realiza mediante una función de exploración de la imagen y la definición de una propiedad, de modo que aquellos píxeles que cumplan dicha propiedad se marcarán como de interés (blancos) y el resto constituirán el fondo (negro). Dada una imagen de partida H y una propiedad P , se crea una imagen F tal que (ecuación 4.4):


$$F(x, y) = \begin{cases} 255 & \text{si } H(x, y) \in P \\ 0 & \text{si } H(x, y) \notin P \end{cases} \quad (4.4)$$

Es evidente que la clave está en la definición de la propiedad P . Como ya se explicó en el apartado anterior, el objetivo es separar los píxeles que representen cobertura vegetal del resto. Ahora bien, la característica que más discrimina a las plantas es sin duda su


4.1. Etapas y métodos del procesamiento de imágenes y plataforma de gestión de imágenes



imagen de partida



(a) $umbral = 195$



(b) $umbral = 227$

Figura 4.6: Resultado de la binarización de la imagen obtenida de la combinación lineal de los planos RGB para valores del umbral distintos

signatura espectral visible (color). La propiedad P deberá determinar si un píxel tiene color 'verde-planta' o no. Más concretamente, P no debe limitarse a definir un color concreto sino una gama de colores, ya que hay que tener en cuenta que muchos píxeles, aunque del mismo color, pueden presentar otra tonalidad debido a sombras o brillos. La incorporación de este último factor en la propiedad P debe hacerse con cuidado ya que puede generar problemas, como incluir, en la región de interés, la sombra de los objetos.

La propiedad P elegida define tanto la gama de color como los límites de sombra y de luminosidad de cada píxel, consiguiendo de esta forma evitar los problemas descritos anteriormente. Para definir la gama de color, P clasifica todos los colores (espacio RGB) en 6 categorías, dependiendo de cuál de los tres planos de color tiene más relevancia a la hora de formar el color definitivo (el valor más alto), y cuál menos (el valor más bajo). De este modo, cada categoría define una gama completa de color, sin importar que éste tenga una mayor o menor intensidad. En la figura 4.7 se expone un ejemplo de lo explicado. La imagen 4.7(a) muestra la categoría en la que el verde es el color prominente y el rojo el de menor relevancia, esto incluye todos aquellos colores situados entre el verde puro y el azul claro, mientras que la figura 4.7(b) define la categoría en la que el verde es el más relevante y el azul el de menor relevancia, determinando verdes más cercanos al amarillo.




Figura 4.7: Determinación de gama de colores mediante la definición de la relevancia en los planos RGB

Una vez comprobado que el píxel explorado corresponde a la gama de color deseada, P verifica que dicho píxel respete también los límites de sombras y luminosidad, que determinan hasta cuánta intensidad de luz o sombra se quiere detectar en la gama de

4.1. Etapas y métodos del procesamiento de imágenes y plataforma de gestión de imágenes

color. Dichos límites se definen en términos de la máxima y mínima intensidad que pueden tomar cada uno de los planos que forman el píxel (tratándose de imágenes de 8 bits, oscilarán entre 0 y 255). Para asegurar que el píxel explorado no pertenece a zonas de sombra, se establece un límite mínimo de intensidad sobre el plano de mayor relevancia. De igual forma, para asegurar que el píxel no pertenece a zonas de luz reflejada, se impone un límite máximo de intensidad sobre el plano de menor relevancia. En la figura 4.8 se muestra un ejemplo del efecto de estas operaciones sobre la gama de colores de la figura 4.7(a) con distinto valor de los límites. La figura 4.8(a) expone el efecto de limitar el exceso de luminosidad, mientras que la figura 4.8(b) muestra el efecto del límite sobre las sombras. En ambos casos se ve cómo se filtran los colores demasiado luminosos en el primer caso y demasiado oscuros en el segundo.




Figura 4.8: Efecto de imponer límites sobre la luminosidad y sombras de un determinado color


Finalmente, la propiedad P o condición que deberán cumplir los píxeles para que se consideren como pertenecientes a la zona de interés, queda como indica la ecuación 4.5, definida la gama de colores mediante los planos de mayor y menor relevancia (*mayor* y *menor*) y los límites de luminosidad y sombras (*luces* y *sombras*).

En la figura 4.9 vemos el resultado final del método **S2** usando valores distintos para los parámetros. Al igual que sucedía en el método **S1**, los parámetros escogidos juegan un papel fundamental en la obtención de los resultados más adecuados para las siguientes etapas y que, además, garanticen una estimación precisa de la zona de vegetación en la imagen.


$$F(x, y) = \begin{cases} 255 & \text{si} \begin{cases} MAX(R(x, y), G(x, y), B(x, y)) = G(x, y) \wedge \\ MIN(R(x, y), G(x, y), B(x, y)) = B(x, y) \wedge \\ MAX(R(x, y), G(x, y), B(x, y)) \geq \text{sombras} \wedge \\ MIN(R(x, y), G(x, y), B(x, y)) \geq \text{luces} \end{cases} \\ 0 & \text{en otro caso} \end{cases} \quad (4.5)$$



imagen de partida



(a) $Luces = 25$, $Sombras = 0$



(b) $Luces = 0$, $Sombras = 150$

Figura 4.9: Resultado de la aplicación del método de segmentación *S2* con distintos valores para los parámetros

4.1.2. Eliminación de las líneas de cultivo

Una vez binarizada la imagen, el siguiente paso es la detección, estimación de densidad y eliminación de las líneas de cultivo. Partiendo de una imagen donde la cubierta vegetal está representada en blanco y el resto en negro, el propósito de esta etapa es diferenciar las líneas de cultivo de las malas hierbas, y eliminar dichas líneas, de modo que en la siguiente etapa sea posible la extracción de las malas hierbas. Al convertir la imagen original en una imagen binaria, la anterior etapa ha eliminado todos los problemas relacionados con las diferencias de iluminación, humedad del suelo, sombras, etc. Sin embargo, en este caso serán determinantes otros factores, como el estado de crecimiento del cultivo y de las malas hierbas, la posición de éstas y la presencia de errores en el sembrado.

Existen varias aplicaciones de visión artificial cuyo objetivo es la detección de las líneas de cultivo. En (Billingsley y Schoenfish, 1997), una vez segmentada la imagen se aplica la transformada de Hough, un método clásico para la detección de líneas en imágenes, de modo que las líneas quedan claramente delimitadas, pudiendo ser usadas para el guiado del tractor. Algo parecido se hace en (Astrand y Baerveldt, 2002), con imágenes en blanco y negro. En (Tellaiche et al., 2008a) se usa también la transformada de Hough una vez segmentada la imagen, aunque en este caso lo que se extraen son los límites de las líneas y no las líneas en sí, demarcando de esta forma las zonas donde pueden encontrarse las infestaciones. En (Sogaard y Olsen, 2003) se divide la imagen en varias franjas horizontales, y se calcula la posición media de cada línea en cada una de las franjas para reconstruir, con esta información, las líneas sobre la imagen original. En (Hague y Tillet, 2001) se usa la óptica de la cámara y su posición con respecto al cultivo para el desarrollo de un filtro de frecuencia que permite detección del cultivo. En (Pérez et al., 2000) se hace una exploración horizontal de la imagen y se toman como posiciones de las líneas de cultivo aquellas donde el valor del histograma alcanza los máximos. Sin embargo, todos estos métodos tienen como objetivo la extracción de las ecuaciones de las rectas que aproximan las líneas de cultivo, mientras que en este caso es necesario detectar con precisión todos los píxeles pertenecientes al cultivo, para dar una estimación precisa de la densidad de éste.

Igual que ocurre en el caso de la segmentación, el funcionamiento de los métodos utilizados es muy dependiente tanto de las características del equipo como de su colo-

cación sobre la escena. Ninguno de los métodos para la detección de líneas de cultivo propuestos hasta ahora tiene en cuenta variaciones en la etapa de crecimiento del cultivo ni de la cantidad de malas hierbas, dando por supuesto siempre que las líneas de cultivo están claramente delimitadas y aisladas. Sin embargo, tal y como ya se explicó en la introducción mediante las imágenes ejemplo de la figura 4.3, pueden producirse casos en los que las líneas son muy difíciles de detectar por su forma, debido a su exceso/defecto de crecimiento, figuras 4.3(f) y (b), a la presencia de errores en el sembrado figura 4.3(e), o a la conexión con el rodal de malas hierbas, figura 4.3(d). Por ello, se han desarrollado tres métodos, **E1**, **E2** y **E3**, para resolver con éxito todas las situaciones encontradas, a expensas, en algunos casos, de aplicar procedimientos computacionalmente más complejos, lo que podría limitar su aplicación en tiempo real. Igual que en la fase de segmentación, cada método usa parámetros de entrada para lograr la mejor adaptación al conjunto de casos.

Método E1 (Vector de columnas)

El primer método es el más sencillo y más rápido. Parte de la base de que todas las imágenes tratadas presentan las líneas de cultivo como columnas verticales en la imagen, por lo que sencillamente localiza y elimina de la imagen toda columna con un número de píxeles blancos considerable. Más concretamente, el procedimiento es el siguiente: explorando la matriz de píxeles de la imagen, se genera un vector que tiene tantas componentes como columnas posee la matriz y cada componente almacena el número de píxeles en blanco en la columna asociada. Una vez construido el vector, se halla la componente o componentes de valor máximo, y se eliminan todas aquellas columnas cuyo valor en el vector (es decir, cuyo número de píxeles) estén comprendidos entre el máximo y el máximo menos un porcentaje definido como parámetro. Es decir, dada la imagen de partida H , y un porcentaje, se crea una imagen F tal que (ecuación 4.6):

$$F(x, y) = \begin{cases} 0 & \text{si } V(x) \geq \text{maximo} * \text{porcentaje} \\ H(x, y) & \text{en otro caso} \end{cases} \quad (4.6)$$

siendo,

$$V(x) = \sum_y H(x, y)$$

4.1. Etapas y métodos del procesamiento de imágenes y plataforma de gestión de imágenes

En la figura 4.10 se muestra el resultado de aplicar este método sobre una misma imagen usando dos valores distintos de porcentaje. Para una mejor comprensión, los píxeles eliminados se muestran en amarillo. En la figura 4.11 vemos el problema que presenta este método ante imágenes con mucha mala hierba, habiendo casos en los que al eliminar las líneas de cultivo con este método se puede eliminar también gran parte de la zona de malas hierbas.




Figura 4.10: Resultado de aplicar el método **E1** con distinto valor de porcentaje

Método **E2** (Vector de filas y mínimo)

Este segundo método mejora al anterior, ya que opera sobre la totalidad de la imagen, en lugar de compactar ésta en un vector de columnas causando pérdida de información. El método **E2** parte de una suposición similar a la del método anterior: la zona central de la línea de cultivo es fácilmente identificable, como la columna cuyo número total de píxeles blancos es el máximo, normalmente similar a la altura de la imagen. Esto es cierto incluso en imágenes con infestación alta de malas hierbas como la de la figura 4.11(a), ya que aunque pueden darse columnas con un número de píxeles blancos muy alto, difícilmente será igual al máximo. Una vez localizados los centros de las líneas de cultivo, **E2** escoge una cualquiera (pueden haber varias) y la toma como punto de partida para un procesamiento por filas que llevará a la eliminación de la línea, repitiendo este proceso tantas veces como sea necesario (hasta que no se




Figura 4.11: Aplicación del método **E1** sobre una imagen infestada


encuentren en la imagen más columnas con un número máximo de píxeles a blanco). Habitualmente, y en el tipo de fotos tomadas, el procedimiento se realiza dos veces, ya que sólo hay dos líneas de cultivo en cada imagen.

El procesamiento efectuado por filas es el siguiente: partiendo del centro de la línea de cultivo y de la primera fila de la imagen, **E2** se va desplazando simultáneamente a la izquierda y a la derecha dentro de esa misma fila, eliminando todos los píxeles por los que pasa, hasta que considere que se ha alcanzado el límite izquierdo/derecho de la línea de cultivo, momento en el que se detiene. Una vez detenido tanto en su recorrido hacia la izquierda como en el de la derecha, pasa a procesar la siguiente fila, y así con todas, quedando la línea de cultivo completamente eliminada. La clave está en cómo determinar si el píxel en una posición concreta sigue estando dentro de la línea de cultivo o no, o lo que es lo mismo, si se ha alcanzado el borde de la línea.

En una primera versión del método, el procesamiento seguía explorando y eliminando píxeles mientras todos los píxeles encontrados fuesen blancos, deteniéndose en el primer píxel negro encontrado. El problema de este procedimiento era que paraba prácticamente nada más empezar, ya que aunque a primera vista parezca que las líneas de cultivo son totalmente densas, en realidad presentan grupos de píxeles negros aislados, formando islotes. Esto se puede observar claramente en la ampliación de una de las líneas de cultivo de la figura 4.6(b), mostrada en la figura 4.12(a). En la figura 4.12(b)

4.1. Etapas y métodos del procesamiento de imágenes y plataforma de gestión de imágenes

se muestra el funcionamiento de la primera versión de **E2** sobre la imagen de la figura 4.6(b).




(a) Ampliación de una línea de cultivo (b) Resultado de la 1ª versión de E2

Figura 4.12: Presencia de píxeles negros aislados dentro de las líneas de cultivo y como afectaban a la primera versión de E2

Para evitar la parada prematura, se usa en cada exploración un vector que almacena tanto el píxel actual como los n siguientes a explorar, decidiendo parar si y sólo si no hay un número mínimo m de píxeles blancos dentro de las posiciones que abarca dicho vector. Los valores tanto de n (tamaño del vector) como de m (mínimo número de píxeles blancos necesarios para continuar el proceso de avance) son parámetros de entrada al algoritmo.

Téngase en cuenta que el proceso explicado se repite tanto hacia la derecha como hacia la izquierda de la columna inicial, para todas las filas de la imagen, además de tantas veces como líneas de cultivo haya presentes en la imagen. En la figura 4.13 se muestran los resultados del método sobre la misma imagen elegida para ilustrar el método **E1** (figura 4.10). Se puede observar el mejor funcionamiento de este método frente al anterior. Otro ejemplo de cómo el método **E2** ajusta mejor que **E1**, se muestra en la figura 4.14, viendo el resultado de **E2** sobre la imagen infestada (figura 4.11(a)). Los valores de n y m tienen gran influencia sobre el ajuste de la operación de eliminación.



(a) $n = 35$, $m = 5$



(b) $n = 39$, $m = 30$

Figura 4.13: Aplicación del método *E2* sobre la misma imagen que en la figura 4.10 con distinto valor para los parámetros n y m




Figura 4.14: Resultado de la aplicación del método *E2* sobre una imagen infestada ($n = 35$, $m = 30$)

Método E3 (Vector filas y bordes)

Teniendo en cuenta la fisonomía de las líneas de cultivo en las imágenes procesadas, los bordes pueden utilizarse como ayuda en la extracción de las mismas. En (Billingsley y Schoenfisch, 1997; Tellaeche et al., 2008a), se usan los bordes como puntos de partida para la posterior aproximación mediante rectas de las líneas de cultivo, usando la transformada de Hough. Este método ha demostrado ser muy eficaz, aunque poco robusto ante imágenes no uniformes, debido a la dificultad al aproximar las rectas cuando el número y posición de los bordes es variable. De todo esto, y como alternativa al método anterior, se propone el método **E3**, que combina el procesamiento por filas de **E2** con la caracterización de las líneas de cultivo mediante operadores de borde. Este método logra mejorar los resultados de **E2**, aunque debido al preprocesamiento de la imagen para la extracción de bordes, es un método computacionalmente costoso y, por tanto, de difícil aplicación en tiempo real.

Un píxel se considera *borde* cuando los píxeles de su alrededor (*vecinos*), presentan una brusca variación con respecto a él en los valores de intensidad. Es decir, los bordes delimitan los puntos frontera a partir de los cuales se producen cambios bruscos en la imagen. Esta información es de gran utilidad para la extracción de contornos, dando lugar a aplicaciones muy variadas, como pueden ser el reconocimiento de objetos, la calibración, o la detección de movimiento (Gonzalez y Woods, 2003; Pajares y de la Cruz, 2007).

La variación de nivel en los píxeles vecinos a un borde no tiene un comportamiento brusco sino progresivo, debido a que el muestreo de las imágenes no es perfecto y produce bordes desdibujados, tal como se muestra en la figura 4.15. La figura 4.15(b) presenta el histograma del valor en intensidad de los píxeles de una línea de exploración horizontal sobre la figura 4.15(a), marcada en blanco. Se puede apreciar claramente cómo al principio y al final se producen cambios de claro a oscuro (y viceversa), marcando el inicio/final del objeto presente, y cómo este cambio no es repentino sino en forma de rampa. Debido a esto, la mayoría de operadores de extracción automática de bordes se basan en derivadas locales sobre la imagen, ya que la derivada tomará valor negativo/positivo en los píxeles que marcan el principio de una rampa y 0 en el resto de píxeles.

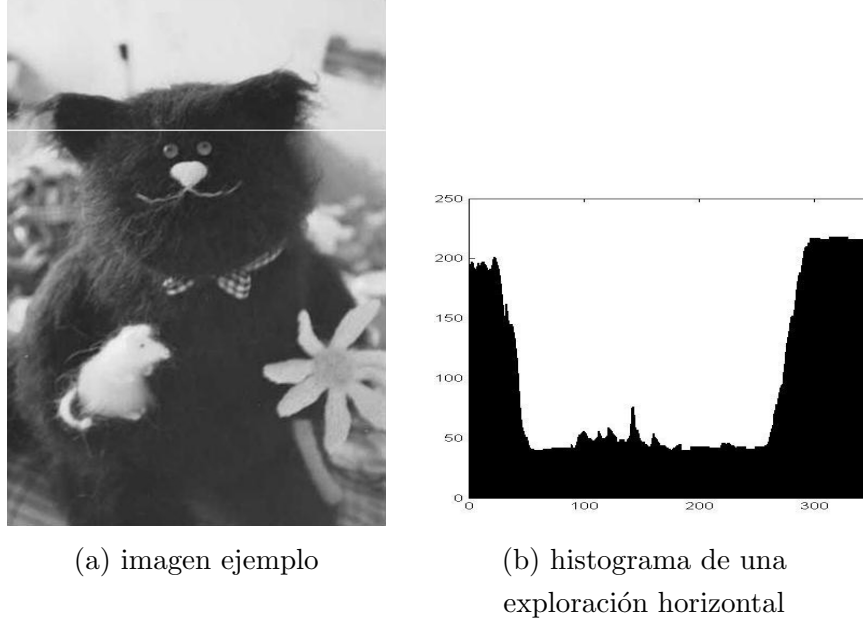


Figura 4.15: Uso del cambio de niveles de intensidad para la extracción de bordes

Ahora bien, en la figura 4.15 sólo se hace una exploración horizontal, por lo que solamente se detectarán *bordes verticales*, es decir, las líneas de contorno verticales del objeto. Esta exploración no detectará ningún cambio de valor que se produzca en sentido vertical (bordes horizontales), ya que para eso es necesario efectuar una exploración vertical de la imagen (por filas en lugar de por columnas). Más concretamente, de cada una de las exploraciones se puede extraer una derivada distinta: la derivada con respecto a x y la derivada con respecto a y , donde x e y son respectivamente las columnas (exploración horizontal) y las filas (exploración vertical). Para detectar correctamente todos los bordes de una imagen, en todos los posibles sentidos (ángulos), es necesario combinar dichas derivadas. El vector bidimensional formado por ambas derivadas se conoce como *gradiente* de una imagen. Dada una imagen H , el gradiente G se construye como (ecuación 4.7):

$$G[H(x, y)] = \begin{bmatrix} G_x \\ G_y \end{bmatrix} = \begin{bmatrix} \frac{\delta}{\delta_x} H(x, y) \\ \frac{\delta}{\delta_y} H(x, y) \end{bmatrix} \quad (4.7)$$

4.1. Etapas y métodos del procesamiento de imágenes y plataforma de gestión de imágenes

El gradiente apunta en la dirección de máxima variación de H en el punto (x,y) con magnitud $|G| = \sqrt{G_x^2 + G_y^2}$ y dirección $\phi = \tan^{-1} \left(\frac{G_y}{G_x} \right)$.

Intuitivamente la derivada en un punto de la imagen se puede calcular mediante las diferencias de primer orden con los píxeles adyacentes. Sin embargo habitualmente se amplía la exploración a más píxeles cercanos además de sólo los adyacentes (normalmente a un entorno de vecindad de 9×9) y después se promedia, para hacer frente a posibles errores de muestreo o ruido y obtener de esta forma mejores resultados. En la literatura se han propuesto muchos métodos distintos para el cálculo de derivadas en imágenes, y por lo tanto diferentes modos de detectar bordes. En la figura 4.16 se muestra un ejemplo de detección de bordes. Partiendo de la imagen 4.16(a), la figura 4.16(b) muestra el resultado de la extracción de bordes mediante un método clásico (Sobel) y la figura 4.16(c) muestra el resultado de otro método, conocido como Canny, que no sólo extrae los bordes sino que además cierra los contornos.

En cuanto al problema de extracción de líneas de cultivo, en la figura 4.17 se ve el resultado de la extracción de bordes (en rojo), sobre una imagen segmentada. Como cabía esperar, tanto las líneas de cultivo como los conjuntos grandes de malas hierbas quedan claramente diferenciados, y además se detectan los islotes negros mencionados en la figura 4.12(a). Esta información puede ser de gran utilidad al añadirse al procesamiento por filas llevado a cabo en **E2**.

El paso inicial en el método **E3** consiste en aplicar una operación de apertura morfológica (erosión seguida de dilatación) sobre la imagen binarizada para eliminar los píxeles aislados y realzar el resto. Luego, **E3** extrae los bordes usando Sobel y marca dichos puntos en rojo. A continuación comienza la eliminación de las líneas de cultivo. El recorrido de exploración sobre la imagen es idéntico al descrito en el método **E2**; es decir se calcula el centro de cada línea de cultivo y se procesa cada fila partiendo de los puntos centrales, desplazándose a la derecha y a la izquierda simultáneamente hasta 'salir' de la línea de cultivo. Lo que cambia con respecto al método **E2** es la decisión sobre qué píxeles eliminar (puesta a negro) y cuándo detener el proceso en la fila. El método **E3** usa 3 parámetros: dos umbrales de distancia en número de píxeles ($\theta_1 \leq \theta_2$) y un porcentaje de eliminación p (similar al usado en el método **E1**).


El funcionamiento de **E3**, dada una imagen de partida H , el píxel actual a , el próximo píxel no negro más cercano s a una distancia d y el porcentaje de eliminación



(a) imagen de partida



(b) bordes (sobel)



(c) bordes + contornos (canny)

Figura 4.16: Extracción de bordes con distinta dirección de gradiente




Figura 4.17: Caracterización de las líneas de cultivo mediante operadores de borde

p se describe a continuación y viene resumido en la Tabla 4.1. Siempre que la distancia al próximo píxel no negro sea mayor que θ_2 , el algoritmo se detiene, ya que al no haber píxeles cercanos ni blancos ni rojos se considera haber llegado al final de la línea de cultivo. En caso contrario, el algoritmo se comporta de forma distinta dependiendo del color de a ¹. Cuando a es blanco, se borran todos los píxeles hasta s y se vuelve a empezar reemplazando a por s , ya que los saltos cortos y medios tanto de blanco a blanco como de blanco a rojo indican que se sigue dentro de la línea de cultivo. Lo mismo sucede con los saltos cortos cuando a es rojo. Sin embargo, en los saltos medios de rojo a rojo sin blancos por medio hay que distinguir entre dos casos: **caso 1**- salto desde el borde de la línea de cultivo al borde de malas hierbas o de otra línea de cultivo (el algoritmo debe detenerse) y **caso 2**- salto entre dos orillas consecutivas de un “islote” negro en el interior de la línea de cultivo (el algoritmo debe continuar). Para distinguir entre estos dos casos, se usa el vector de columnas del método **E1**, usado en la detección del punto central de la línea de cultivo, que contenía para cada columna el número total de píxeles blancos. Si la proporción de píxeles blancos entre a y s sobre el total de píxeles es mayor que p , significa que en general entre a y s hay muchos blancos salvo en la fila actual (en la que no hay blancos), por lo que se trata de una zona negra aislada, caso 2. Si por el contrario la proporción de blancos es menor que p será porque

¹Nótese que se considera también la posibilidad de que el píxel actual a sea negro, porque aunque nunca se salta hasta un píxel negro sí es posible que el algoritmo empiece situado en un píxel negro

es una zona negra en todas las filas, caso 1. Por último, si a es negro, simplemente se avanza hasta s sin borrar nada y se remplacea a por s para empezar en un píxel blanco o rojo. Cabe resaltar que si el valor de ambos umbrales es el mismo ($\theta_1 = \theta_2$), **E3** sólo detectará saltos medios o largos, nunca cortos, no ejecutándose nunca la segunda columna ($d < \theta_1$) de la Tabla 4.1.


Tipo del píxel actual a	Distancia d (en píxeles) hasta próximo píxel no negro s		
	$d \leq \theta_1$	$\theta_1 < d \leq \theta_2$	$d > \theta_2$
Blanco	Elimina todos los píxeles desde a hasta s y salta hasta s ($a \leftarrow s$)	Elimina todos los píxeles desde a hasta s y salta hasta s ($a \leftarrow s$)	Fin
Borde	Elimina todos los píxeles desde a hasta s y salta hasta s ($a \leftarrow s$)	SI $\sum_y H(a \dots s, y) > \text{maximo} * p$ ENTONCES Elimina todos los píxeles desde a hasta s y salta hasta s ($a \leftarrow s$) SI NO Fin	Fin
Negro	Salta hasta s ($a \leftarrow s$)	Salta hasta s ($a \leftarrow s$)	Fin

Tabla 4.1: Funcionamiento del método **E3**


La fuerza de **E3** reside sobre todo en el uso de los bordes (píxeles rojos) para la detección de zonas negras aisladas dentro de la línea de cultivo, cosa que ninguno de los métodos anteriores considera. En la figura 4.18 vemos los resultados de aplicar este método en las mismas imágenes utilizadas como ejemplo para **E1** y **E2**. Se aprecia fácilmente cómo el ajuste a las líneas de cultivo es mejor que el de los métodos anteriores, sobre todo en la imagen infestada, figura 4.18(c). Además, se comprueba también que el valor de los parámetros no es tan determinante como en los otros métodos, debido a que el uso de dos umbrales de distancia, en lugar de uno sólo, hace que el procesamiento sea más robusto.



(a) $\theta_1 = 15$, $\theta_2 = 30$, $p = 80\%$



(b) $\theta_1 = 50$, $\theta_2 = 60$, $p = 60\%$



c) $\theta_1 = 2$, $\theta_2 = 5$, $p = 60\%$

Figura 4.18: Resultado de aplicar el método **E3** con distinto valor para los parámetros

4.1.3. Filtrado de las malas hierbas

El objetivo de los métodos de eliminación de las líneas de cultivo es que todo píxel blanco presente en la imagen resultante, pertenezca a zonas de mala hierba. Sin embargo, las imágenes procesadas pueden presentar situaciones muy variadas y no siempre es fácil adaptarse a cada situación y lograr la correcta eliminación de toda línea de cultivo para todos los casos. Esta etapa podría considerarse una etapa de detección de malas hierbas, similar a las varias vistas en el Capítulo 3. Sin embargo, las malas hierbas encontradas sólo pueden discriminarse por su posición (entre las líneas de cultivo), no sirviendo ninguno de los métodos existentes que se basan principalmente en clasificaciones por tamaño, forma o color. En consecuencia, esta última etapa se considera más bien una fase de filtrado.

Existen muchos factores que influyen en el correcto resultado de la fase de filtrado, desde el valor de los parámetros, hasta la calidad y tipo de la imagen, factores difíciles de controlar. En concreto, los objetivos de esta etapa son: 1) quitar todos los píxeles que no estén entre las líneas de cultivo eliminadas, ya que las malas hierbas sólo se manifiestan entre líneas y 2) discriminar entre los píxeles aislados (restos de líneas de cultivo no eliminadas correctamente o ruido en la imagen original) y los píxeles que pertenecen a zonas de malas hierbas.

Para lograr el primer objetivo hay que determinar las posiciones de comienzo y final de todas las líneas de cultivo y eliminar todo píxel blanco que no se encuentre entre dos líneas consecutivas. La posición de cada línea de cultivo se determina al final de la etapa de eliminación, ya que se necesita la información usada durante esa etapa para saber la localización de éstas. En la figura 4.19 se muestra gráficamente cómo se consigue el primer objetivo dependiendo de si se ha usado el método **E1**, figura 4.19(a), o los métodos **E2** y **E3**, figura 4.19(b). En el primer caso, teniendo en cuenta que el método **E1** elimina columnas enteras, se puede considerar como límite izquierdo de la primera línea de cultivo la columna eliminada más a la izquierda, y del mismo modo la columna eliminada más a la derecha determina el límite derecho de la segunda línea de cultivo (o de la última en caso de haber más de dos). Debido a que **E1** se encarga de eliminar el cultivo, una vez localizados ambos límites, basta eliminar todo píxel entre dichos límites izquierdo/derecho y el inicio/final de la imagen para conseguir lo deseado, tal como se muestra en rojo en la figura 4.19(a).

4.1. Etapas y métodos del procesamiento de imágenes y plataforma de gestión de imágenes

Para los métodos **E2** o **E3**, el cálculo de los límites del cultivo es más complicado ya que no se elimina toda la columna de modo uniforme. Lo que se hace en este caso es hallar las columnas medias de eliminación de cada cultivo, calculando la media aritmética de las posiciones numéricas de las columnas de la imagen en las que se ha detenido el procesamiento en cada lado y en cada línea de cultivo. Una vez conocidos los límites, se eliminan todos los píxeles que no se encuentren entre el límite derecho de la primera línea de cultivo, $I2$, y el límite izquierdo de la segunda línea de cultivo, $D1$. En la imagen 4.19b se muestran estos límites (en azul y marcados respectivamente como $I1$, $I2$, $D1$ y $D2$) y las zonas que se eliminan finalmente de la imagen (en rojo).

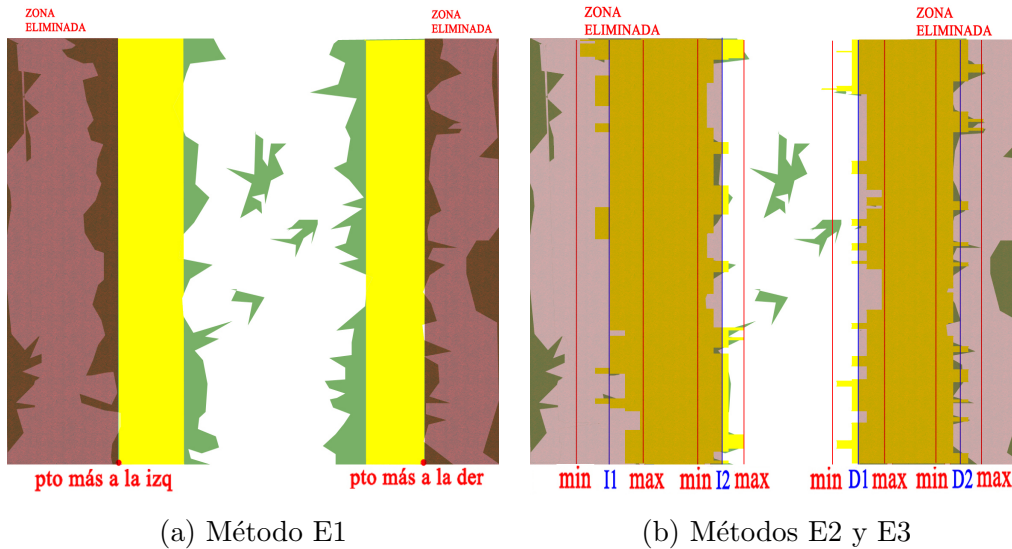


Figura 4.19: Identificación de los bordes de las líneas de cultivo en **E1**, **E2** y **E3**

En cuanto al segundo objetivo, discriminar entre píxeles aislados (ruido) y aquellos que provienen de una zona de infestación, es algo más complicado, y para su consecución se han desarrollado tres métodos distintos: **F1**, **F2** y **F3**, explicados a continuación.

Método F1 (Iterativo con entorno de vecindad)

El objetivo principal de la etapa de filtrado, una vez descartadas las zonas exteriores al espaciado entre las líneas de cultivo, es la detección de las malas hierbas caracterizadas como agrupamientos de píxeles blancos en una misma zona, mediante

la eliminación de los píxeles aislados o ruido. **F1** realiza esto de la forma más sencilla; para cada píxel blanco presente en la imagen determina si éste pertenece o no a mala hierba, analizando el entorno de vecindad del píxel. Más detalladamente, para cada píxel blanco **F1** explora el entorno de vecindad de $radio \times radio$ píxeles (donde $radio$ es un parámetro predefinido), y calcula la proporción de blancos que hay en dicho entorno. Esta proporción da una medida de lo aislado o agrupado que está el píxel. El método **F1** usa dos umbrales ($\theta_{limpia} \leq \theta_{realza}$), de modo que por debajo del primero borra el píxel y todos los píxeles del entorno de vecindad, y por encima del segundo pone todos a blancos, no realizando ninguna modificación si la proporción se encuentra entre ambos umbrales. En la figura 4.20 se muestra el funcionamiento de este modo de filtrado. Los píxeles del área marcada en rojo, que tiene una proporción alta de blancos ($proporcion \geq \theta_{realza}$), se pondrán todos a blanco. En el área marcada en amarillo, como hay pocos blancos ($\theta_{limpia} \leq proporcion$), los píxeles se pondrán a negro, o lo que es lo mismo, se eliminarán. Por último, en el área verde la proporción está comprendida entre los umbrales definidos ($\theta_{limpia} < proporcion < \theta_{realza}$), por lo que **F1**, en este caso, no hace nada. Nótese que si $\theta_{limpia} = 0$, **F1** no eliminará ningún píxel; de modo análogo, si $\theta_{realza} = 1$ nunca se agruparán píxeles. Además, **F1** es un método iterativo, efectuando tantas iteraciones como el valor de su cuarto parámetro, It , indique.




Figura 4.20: Ejemplo de los 3 tipos de operación efectuados por **F1**

El resultado de la aplicación del método **F1**, es bastante satisfactorio, ya que elimina píxeles aislados, muchos de ellos procedentes del ruido y a la vez dilata las zonas blancas (malas hierbas), tal y como se deseaba. En la figura 4.21 se ve el resultado de este método

4.1. Etapas y métodos del procesamiento de imágenes y plataforma de gestión de imágenes

sobre una misma imagen, figura 4.21(a) usando valores distintos de los parámetros. Se observa cómo el método funciona bastante bien, dejando después de varias iteraciones sólo la mala hierba. El gran problema de **F1** es su altísima complejidad, alcanzando en el peor de los casos una complejidad de orden $\Theta(N \times M \times radio^2 \times It)$, siendo $N \times M$ el tamaño de la imagen, *radio* el tamaño del entorno de vecindad explorado e *It* el número de iteraciones. Todo esto se traduce en tiempos de ejecución inaceptables (véase el capítulo de resultados), sobre todo con valores de *radio* o de *It* grandes, lo que convierte en inviable el uso del método sobre varias imágenes a la vez y más aún si se quiere utilizar en procesamiento de imágenes en tiempo real.


Método F2 (Agrupación de regiones)

El segundo método desarrollado también diferencia los píxeles de mala hierba del resto según si el píxel forma parte de un grupo suficientemente grande de píxeles blancos. El método **F2** usa el concepto de región. En concreto, dos píxeles blancos pertenecerán a la misma región si están conectados entre sí, o lo que es lo mismo, todos los píxeles conectados entre sí forman parte de una misma región. Se entiende por conectado el hecho de pertenecer a la misma región de vecindad espacial, que en este caso se ha definido de 3×3 .


F2 identifica dentro de la imagen las regiones blancas como entes independientes y almacena cada región en un vector de regiones, transformando de este modo la imagen binaria a un TAD (Tipo Abstracto de Datos) que contiene las regiones localizadas y organizadas. Para localizar las regiones presentes en la imagen, **F2** debe computar qué píxeles están conectados entre sí para situarlos en la misma región. Esto requiere, para cada píxel *i*, comprobar el valor de sus 8 vecinos:

$$\begin{pmatrix} v1 & v2 & v3 \\ v4 & i & v5 \\ v6 & v7 & v8 \end{pmatrix}$$


Sin embargo, se puede reducir dicha comprobación a sólo 4 vecinos si se recorre la imagen ordenadamente, desde su extremo izquierdo superior hasta su extremo derecho



(a) imagen de partida



(b) $radio = 4$, $It = 5$,
 $\theta_{limpia} = 0,7$, $\theta_{realza} = 0,7$



(c) $radio = 3$, $It = 2$,
 $\theta_{limpia} = 0,3$, $\theta_{realza} = 0,8$

Figura 4.21: Resultados de la aplicación del método **F1** con distintos valores para los parámetros


4.1. Etapas y métodos del procesamiento de imágenes y plataforma de gestión de imágenes

inferior, y para cada píxel blanco encontrado se comprueba sólo el valor de sus píxeles vecinos que hayan sido ya explorados, que por el orden de recorrido serían sólo los 4 primeros ($v1 \dots v4$). Si alguno de ellos es blanco, el píxel actual pasa a formar parte de la misma región que dicho vecino (ya que al haber sido ya explorado ha tenido que ser incluido en alguna región), y si por el contrario ninguno de ellos es blanco, el píxel actual crea una nueva región de la que de momento será su único miembro. Asimismo, si el píxel actual tiene varios vecinos blancos y éstos no están en la misma región (puede ocurrir por ejemplo cuando $v1$ y $v3$ son blancos pero $v2$ no), deberán unirse las regiones asociadas a dichos vecinos en una única región e incluir en ella al píxel actual. En la figura 4.22 se muestra un ejemplo del resultado de este procedimiento. A la izquierda se presenta la matriz de valores de la imagen procesada, y a la derecha la pertenencia de cada píxel blanco a una u otra figura. Se ve claramente cómo las regiones formadas pueden tener píxeles negros en medio ($R1$), lo que permite la correcta extracción de las zonas de malas hierbas.


$$\left(\begin{array}{cccccccccc} 1 & 0 & 0 & 0 & 1 & 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 0 & 0 & 0 & 1 & 1 & 1 & 1 & 0 \\ 1 & 1 & 1 & 0 & 1 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 & 1 & 1 & 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 1 & 1 & 1 & 0 & 0 & 1 & 1 \\ 0 & 1 & 0 & 1 & 1 & 1 & 0 & 0 & 0 & 1 \\ 0 & 1 & 0 & 1 & 1 & 1 & 0 & 0 & 0 & 0 \\ 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \end{array} \right) \quad \left(\begin{array}{cccccccccc} R1 & 0 & 0 & 0 & R1 & R1 & R1 & R1 & R1 & R1 \\ R1 & R1 & 0 & 0 & 0 & R1 & R1 & R1 & R1 & 0 \\ R1 & R1 & R1 & 0 & R1 & 0 & 0 & 0 & R1 & 0 \\ 0 & 0 & 0 & R1 & 0 & 0 & 0 & R1 & 0 & 0 \\ 0 & 0 & R1 & 0 & R1 & R1 & R1 & 0 & 0 & 0 \\ 0 & R1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & R2 \\ 0 & 0 & 0 & R3 & R3 & R3 & 0 & 0 & R2 & R2 \\ 0 & R4 & 0 & R3 & R3 & R3 & 0 & 0 & 0 & R2 \\ 0 & R4 & 0 & R3 & R3 & R3 & 0 & 0 & 0 & 0 \\ R4 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \end{array} \right)$$

Figura 4.22: Extracción de regiones en el método **F2**


Una vez detectadas todas las regiones extraídas, **F2** las ordena de mayor a menor, y elimina todas aquellas que no tengan un número de píxeles dentro del porcentaje establecido como parámetro, que se fija con respecto al tamaño de la región más grande de todas las extraídas. De este modo se filtran todas aquellas regiones que no denotan una agrupación considerable de píxeles (malas hierbas). La figura 4.23 muestra los resultados de este método sobre la imagen de partida 4.21(a) para distintos valores del parámetro de entrada al método. Cómo se puede observar, los resultados obtenidos son mejores que los obtenidos con **F1**, con un coste computacional menor y usando un único parámetro de entrada.



(a) imagen de partida



(b) porcentaje = 5 %



(c) porcentaje = 30 %

Figura 4.23: Resultados de la ejecución del método **F2** para distintos valores de su parámetro de entrada

Método F3 (Agrupación de regiones + densificación)

El método anterior, aunque proporciona buenos resultados en la mayoría de las imágenes, no se ajusta suficientemente bien en algunos casos. El primer problema que presenta **F2** se debe a que en ciertas imágenes aparecen fragmentos en regiones que a simple vista parecen unidas completamente. En la figura 4.24(a) se muestra una ampliación de la mala hierba central de la imagen 4.21(a), que a primera vista parecía una única región, estando sin embargo fraccionada en diversos puntos (marcados en rojo). Debido a esto, **F2** extraerá tres regiones en lugar de una única, y se corre el riesgo de que al ser más pequeñas se filtren incorrectamente. Para subsanar este tipo de situaciones, **F3** realiza una operación morfológica de apertura sobre la imagen de partida antes de la extracción de regiones, operación que “conecta” todas las regiones grandes levemente fracturadas. En la figura 4.24(b) se muestra el resultado de la apertura sobre la región de la figura 4.24(a), viéndose claramente cómo todas las regiones se agrupan en una única, sin por ello cambiar la fisonomía de la imagen original. Gracias a la ejecución de esta simple operación morfológica, antes de la extracción de regiones, **F3** extrae regiones que se ajustan mejor a la realidad que las que obtiene **F2**.






Figura 4.24: Regiones fraccionadas

La otra diferencia entre **F3** y **F2** reside en que **F3** efectúa una operación morfológica de dilatación sobre la imagen resultante de la agrupación de regiones, de modo que la mala hierba final se ajuste más a la realidad y a un tratamiento eficaz, que en caso de duda aplica herbicida de modo preventivo. La figura 4.25 muestra los resultados


de este método sobre la imagen de partida 4.21(a) con distinto valor del parámetro de entrada. Como se puede observar, los resultados obtenidos son ligeramente distintos y mejores que los obtenidos con el método **F2**.



(a) imagen de partida



(c) porcentaje = 5 %



(d) porcentaje = 30 %

Figura 4.25: Resultados de la ejecución del método **F3** para distintos valores de su parámetro de entrada

4.1.4. Plataforma de gestión de imágenes

Una vez implementados los métodos de procesamiento de imágenes, se diseñó y desarrolló una plataforma donde se incluyeron todos los elementos necesarios para ayudar a los expertos en todo el proceso de construcción de los mapas de cobertura de

4.1. Etapas y métodos del procesamiento de imágenes y plataforma de gestión de imágenes

malas hierbas y estado de crecimiento del cultivo a partir del muestreo fotográfico. La aplicación permite el manejo de imágenes (abrir/cerrar, visualizar, guardar), el procesamiento de las mismas, utilizando los métodos descritos, y el análisis de los resultados obtenidos. Esta plataforma fue desarrollada en C++ en el entorno de programación C++Builder de Borland©, y dispone de una interfaz gráfica de usuario (GUI) lo más sencilla e intuitiva posible para que pueda ser usada por cualquier tipo de usuario sin necesidad de experiencia previa en análisis de imagen. En la figura 4.26 se pueden ver algunas capturas de pantalla.

El procesamiento de las imágenes usando la plataforma puede llevarse a cabo de varias formas, ya sea imagen a imagen o varias a la vez, con la opción de procesarlas de forma manual visualizando el resultado de cada etapa del procesamiento, figuras 4.26(a) y 4.26(b), o automáticamente mostrando sólo el resultado y valores finales de cobertura. Todo esto permitiendo en todo momento el cambio de los métodos a usar en cada etapa y el valor de los parámetros que éstos requieren en su ejecución.

En el análisis de los resultados también se ofrecen varias funciones distintas. Se puede desde simplemente visualizar los píxeles resultantes de mala hierba, cultivo y suelo (figura 4.26(c)), hasta construir una base de datos con los valores de cobertura obtenidos y construir a partir de ella los mapas de índice de cobertura de malas hierbas y estado de crecimiento del cultivo del campo, figura 4.26(d).

La construcción de los mapas de cobertura asociados a los valores obtenidos para cada imagen de muestreo se llevan a cabo usando una técnica de interpolación. En la actualidad está implementada una técnica conocida como *kriging* (Cressie, 1993), aunque el objetivo es que la plataforma disponga de varios métodos de interpolación de modo que el usuario pueda seleccionar el más adecuado.

El kriging es un conjunto de técnicas geoestadísticas, perteneciente a la familia de estimadores lineales, orientadas a la interpolación de valores no conocidos a partir de valores observados cercanos. Más concretamente, dada una serie de valores asociados a puntos de muestreo (para cada uno de los cuales se conoce su localización GPS), se estima el valor de los puntos del mapa x_0 para los cuales no se dispone de información de muestreo a partir de los valores recogidos en todos los puntos de muestreo $Z(x_1) \dots Z(x_N)$, asignando a cada valor recogido un peso $w_i(x_0)$ en el cómputo global, inversamente proporcional a la cercanía de dicho punto con respecto a la posición cuyo

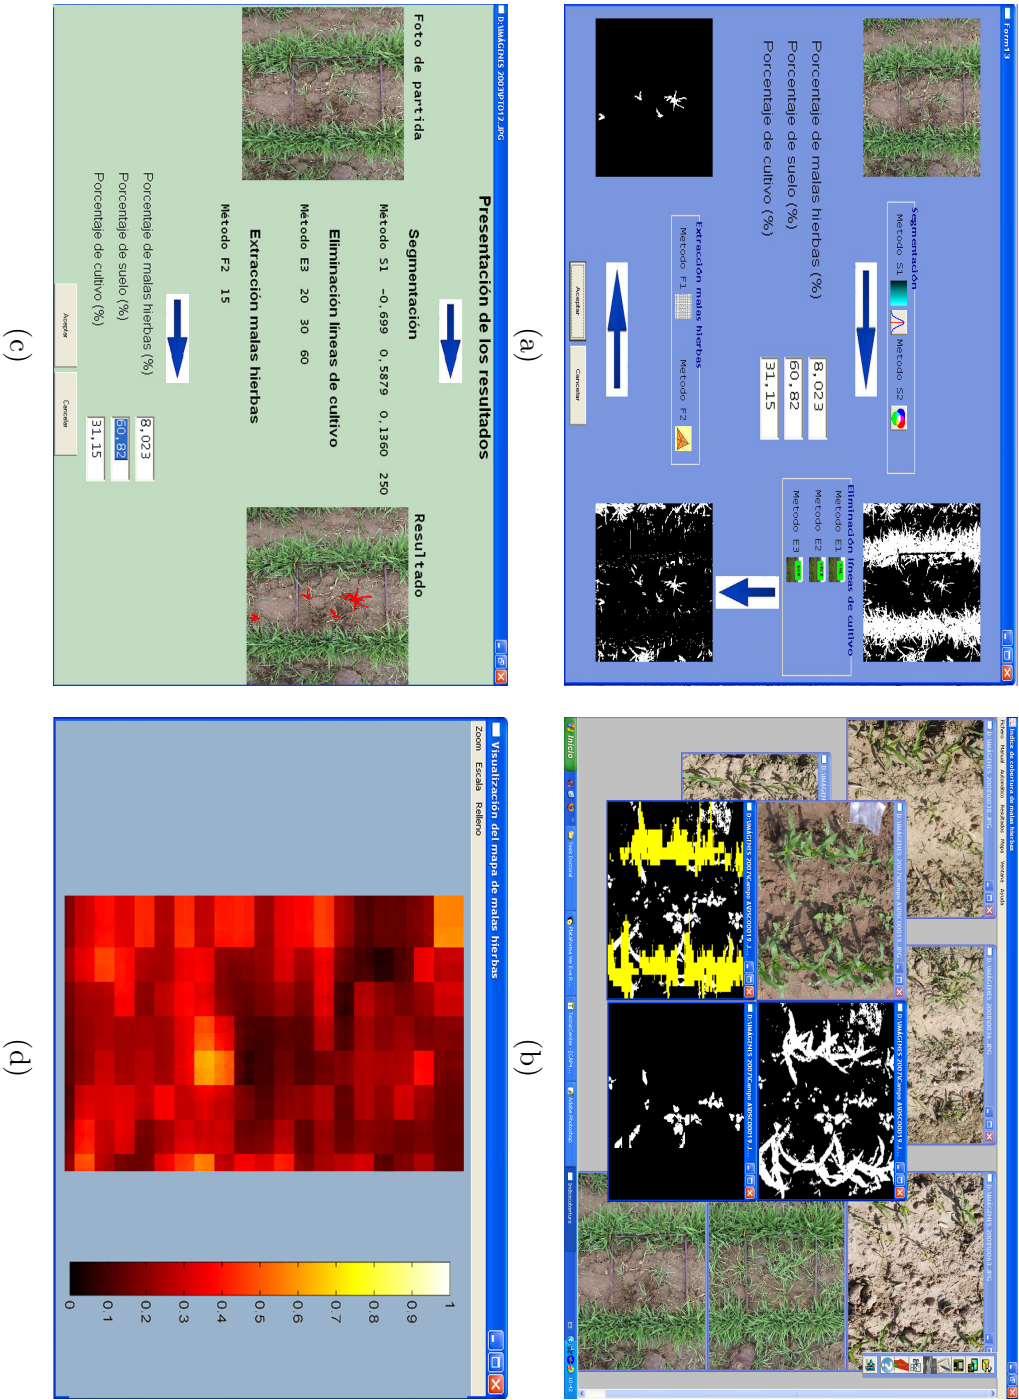


Figura 4.26: Plataforma de procesamiento de imágenes

4.1. Etapas y métodos del procesamiento de imágenes y plataforma de gestión de imágenes

valor se desea estimar, ecuación 4.8.

$$Z^*(x_0) = \sum_{i=1}^N w_i(x_0) Z(x_i) \quad (4.8)$$

Los pesos w_i son soluciones a un sistema de ecuaciones lineal obtenido asumiendo que el error cometido en la estimación, con respecto a la función real $z(x)$, ver ecuación 4.9, debe ser minimizado. Por ejemplo, en un kriging simple, se parte de la hipótesis de que la media y la covarianza de $z(x)$ son conocidas, y se considera que el estimador debe minimizar la varianza del error en la predicción.

$$\epsilon(x) = z(x) - \sum_{i=1}^N w_i(x) Z(x_i) \quad (4.9)$$

Dado que en este caso los valores a estimar son valores de densidades de vegetación (cultivo y malas hierbas), cada punto del mapa se estima a partir únicamente de los puntos de muestreo más cercanos, ya que las densidades de vegetación están relacionadas entre sí en áreas pequeñas, pero nunca entre áreas muy alejadas del campo.

La figura 4.27 muestra el método de kriging incluido en la plataforma de procesamiento de imágenes. Dado un punto para el cual no se tiene información, su valor se estima en función de los valores correspondientes a los 16 puntos de muestreo más cercanos distribuidos en un entorno de vecindad de 4×4 , siendo el peso de cada uno de los valores en los puntos muestreados inversamente proporcional a la distancia entre el punto de muestreo x_i y el punto a estimar x_0 , normalizada con respecto a la distancia máxima (distancia entre x_1 y x_{16}). Las distancias se miden en distancia de Manhattan (distancia en el eje x + distancia en el eje y).

El usuario decide, al usar la plataforma, la resolución de los mapas (tanto en el eje x, como en el eje y), aunque por defecto se ha fijado una resolución de $1m \times 1m (1m^2)$. Por último, recalcar que aunque éste es el método actualmente incluido en la plata-




Figura 4.27: Método de interpolación para la construcción de los mapas a partir del muestreo discreto

forma, se podría incluir cualquier otro de forma sencilla y rápida, ya que el cálculo de interpolación se halla separado de todas las demás funciones de la plataforma.

4.2. Ajuste del procesamiento de imágenes mediante algoritmos genéticos

Cada uno de los métodos propuestos en la sección 4.1 utiliza un cierto número de parámetros de entrada que varían en un amplio rango de valores. El valor de los parámetros determinará la forma en la que los métodos funcionan sobre una imagen determinada, y por lo tanto es de esperar que para cada imagen el conjunto de valores de los parámetros que proporcione resultados óptimos sea distinto. Más aún, la combinación de métodos usados en el procesamiento (qué método se usa en cada una de las etapas) también tendrá una gran influencia en los resultados finales, ya que como se ha visto cada método presenta ventajas o inconvenientes dependiendo de la naturaleza de la imagen procesada.

Ni la mejor combinación de métodos ni el mejor valor para los parámetros puede ser

4.2. Ajuste del procesamiento de imágenes mediante algoritmos genéticos

determinada por prueba y error, ni tan siquiera por parte de usuarios expertos, debido a que el número de posibles combinaciones de métodos y valor de los parámetros es prácticamente infinito (valores numéricos), e imposible de predecir sobre conjuntos grandes de imágenes. Por lo tanto es necesaria la aplicación de algún método de ajuste que indique, dado un conjunto de imágenes a tratar cuál es el mejor procesamiento aplicable, tanto en términos de la mejor combinación de métodos como en lo que al valor de los parámetros se refiere. Esta operación de ajuste permitirá optimizar toda la plataforma de procesamiento de imágenes, ya que los valores hallados podrán usarse como valores de partida en posteriores procesamientos y serán también un medio de evaluar la plataforma, al valorar cuantitativamente los resultados obtenidos por las soluciones óptimas encontradas.

Desafortunadamente, las mismas razones que imposibilitaban un ajuste manual, complican también el diseño del método de ajuste automático. Es decir, nos encontramos con distintas combinaciones de métodos posibles, valores de los parámetros en rangos infinitos al tratarse de valores numéricos y falta de conocimiento a priori sobre cómo se comporta el sistema ante cada cambio. Esto conduce a un espacio de búsqueda de soluciones prácticamente infinito, con el agravante de que no se dispone de ninguna información sobre dónde se pueden encontrar las soluciones óptimas.

Existe una extensa bibliografía sobre algoritmos de optimización convencionales, entre los que destacan los basados en gradiente, que se dirigen hacia la solución más próxima siguiendo la dirección en la que el gradiente disminuye o aumenta (minimización o maximización), sin capacidad para distinguir entre una solución local y una global. Entre las alternativas disponibles destacan los Algoritmos Genéticos (AG) que han alcanzado una gran popularidad por su flexibilidad y capacidad para resolver problemas complejos de naturaleza muy diversa (Booker et al., 1989; Buckles y Petry, 1992; Goldberg, 1989; Holland, 1975; Michalewicz, 1996; Miettinen et al., 1999). Los AG forman parte del llamado cómputo evolutivo (*Evolutionary Computation*), que además de los AG incluye la programación evolutiva, las estrategias de evolución y la programación genética, o lo que es lo mismo, diferentes metodologías computacionales estocásticas que se inspiran en la evolución biológica.

Centrándonos en los AG, éstos se definen como métodos estocásticos de optimización global basados en los principios de la selección y evolución natural (Davis, 1987; Gold-

berg, 1989). De acuerdo con la teoría de la evolución de Darwin, en los AG la evolución entre generaciones promueve la supervivencia de los mejores individuos. Básicamente, una población de individuos o soluciones potenciales a un problema, adecuadamente codificadas, se hace evolucionar hacia una solución óptima mediante la presión que ejercen los operadores de selección, cruce y mutación, utilizando una función de coste o función de *fitness* para medir la calidad de las soluciones y proceder a generar una nueva generación de individuos o soluciones.

El desarrollo conceptual de los AG tiene, desde sus orígenes, un respaldo matemático que garantiza la convergencia hacia soluciones óptimas, basado principalmente en el denominado teorema del esquema, que conjuga *fitness*, cruce y mutación para establecer cómo afectan a la supervivencia y propagación de las soluciones el esquema de representación de los datos. Con las bases del método bien definidas, pueden intuirse una serie de ventajas de los AG frente a los métodos clásicos de optimización local. En primer lugar, el resultado de un método clásico de optimización depende del punto de arranque, mientras que los AG son independientes de las condiciones iniciales. En general, las técnicas globales de optimización se desenvuelven con eficacia en espacios multidimensionales y con múltiples discontinuidades, donde los métodos locales se muestran ineficaces. En este sentido y ante problemas en los que la naturaleza del espacio de soluciones se desconoce, los métodos globales son particularmente útiles. Los AG llegan a una solución global o próxima a ésta, en lugar de converger hacia soluciones locales como puede ocurrir con los métodos convencionales. Existen otras razones que hacen que los AG sean más flexibles y potentes que las técnicas de optimización local, tales como: 1) realizar en cada iteración una búsqueda paralela, en el espacio de soluciones, en la que se exploran varias soluciones simultáneamente frente a examinar una sola solución del espacio; 2) utilizar una función de *fitness* para dirigir la búsqueda en lugar de derivadas; o 3) que los nuevos puntos/soluciones a explorar se determinen de acuerdo a reglas de decisión estocásticas en lugar de deterministas. Como contrapartida, la naturaleza estocástica de los AG, con una exploración mucho más exhaustiva del espacio de soluciones, suministra una convergencia mucho más lenta que la de los métodos locales.

Los AG han sido aplicados con éxito durante varias décadas a todo tipo de problemas y así se pueden encontrar aplicaciones en campos tan variados como biología, economía, robótica, física, política, etc. (Abraham et al., 2008; Miettinen et al., 1999).

4.2. Ajuste del procesamiento de imágenes mediante algoritmos genéticos

La aplicación en el procesamiento de imágenes es algo relativamente reciente, si se compara con el tiempo que esta técnica lleva siendo utilizada. Una de sus aplicaciones más frecuentes del los AG en el área de VA es para mejorar la clasificación de objetos en la imagen, ajustando los resultados de los clasificadores o *clusters* (Andrey y Tarroux, 1994; Bazi et al., 2007; Bhandarkar y Zhang, 1999; Bhanu et al., 1995; Veenman et al., 2003). Por ejemplo, en Ribeiro et al. (2000) se utilizan los AG para optimizar el proceso de clasificación mediante visión y en tiempo real de huevos sucios en una cadena de empaquetado en una granja. De forma parecida pueden también usarse para ajustar la extracción de distintos tipos de texturas dentro de una imagen (Li y Chiao, 2003), o para detectar los distintos colores presentes (Shyu y Leou, 1998). En Bevilacqua (2005) se usan AG para resolver un problema muy similar al planteado en esta tesis, en este caso se ajustan los parámetros de un procesamiento de imágenes que permite la detección de movimiento. En lo que sigue se presentan los dos tipos de algoritmos genéticos que se han utilizado para encontrar la combinación de métodos y parámetros que mejor procesa, en media, un conjunto de imágenes con la finalidad de estimar automáticamente las coberturas de suelo, cultivo e infestación.

4.2.1. Ajuste mediante un algoritmo genético simple o estándar

Como se ha expuesto hasta ahora, los AG son métodos estocásticos de búsqueda basados en los principios de la evolución biológica. En términos de evolución biológica, básicamente un organismo se compone de células, cada una de las cuales contiene el mismo conjunto de cromosomas. A su vez, los cromosomas, compuestos por genes, son cadenas de ADN que definen un modelo para todo el organismo. Cada gen codifica una cierta proteína, puede decirse que codifica un rasgo del organismo, y los valores que puede tomar un rasgo reciben el nombre de alelos; asimismo cada gen ocupa su propia posición dentro del cromosoma. A grandes rasgos, la evolución generacional alterará los cromosomas y, en consecuencia, las características de los nuevos organismos. En la terminología utilizada en los AG, cada uno de los parámetros a optimizar se identifica con un gen y el conjunto de todos ellos representa a un cromosoma, que en realidad puede verse como una solución potencial al problema. El rango dinámico de cada variable o gen equivale a los alelos y, en conjunto, el rango dinámico de los N genes define el espacio de búsqueda N -dimensional. Para formalizar la búsqueda,

una población de I cromosomas o individuos que codifican I soluciones potenciales (suponemos un individuo formado por un único cromosoma) se hace evolucionar a través de la sucesión de generaciones hacia una solución óptima, aplicando sobre los individuos operaciones de selección, cruce y mutación que garantizan la supervivencia de los mejores, utilizando una función conocida como función de *fitness* para cuantificar la calidad de cada uno de los individuos de la generación. La estructura básica de un AG simple se muestra en la figura 4.28.

```
t = 0;
Generar Población inicial  $Pob(t)$ ;
Evaluar Población  $Pob(t)$ ;
Mientras no alcanzar solución óptima o condición parada Hacer
    Generar Población  $Pob(t + 1)$ 
        Selección;
        Cruce;
        Mutación;
    FinGenerar
    Evaluar  $Pob(t + 1)$ ;
    [Elitismo];
    t = t + 1;
FinMientras
Devolver el mejor individuo de la última población;
```

Figura 4.28: Estructura de un AG

El operador de elitismo puede estar o no presente en la ejecución de un AG estándar y se introduce, en su forma más sencilla, para preservar el mejor individuo entre generaciones y garantizar la convergencia.

En resumen, a la hora de utilizar un AG para resolver un problema hay 6 aspectos esenciales que deben establecerse (Michalewicz, 1996):

1. Cómo se codificarán las soluciones (individuos) y que alfabeto de utilizará. La utilización de alfabetos de baja cardinalidad, como el binario, es habitual pues simplifica la implementación de los operadores genéticos de cruce y mutación.
2. Qué operadores genéticos de selección, cruce y mutación se van a utilizar. Son

4.2. Ajuste del procesamiento de imágenes mediante algoritmos genéticos

estos operadores los que nos permiten construir soluciones a partir de otras y con ello explorar el espacio de búsqueda.

3. La función de evaluación de la calidad de las soluciones o función fitness, que permite comparar soluciones y guiar la búsqueda hacia zonas del espacio de soluciones más prometedoras.
4. Los valores de los distintos parámetros que utiliza el algoritmo genético como la probabilidad de cruce y mutación, las condiciones de terminación, etc.
5. La función de construcción de la población inicial. Ésta con frecuencia se genera de modo aleatorio, aunque en algunos casos si se dispone de conocimiento sobre cómo es la solución se puede utilizar éste para crear una población de soluciones de partida.
6. El número de individuos en la población determina las exploraciones que se realizan en paralelo por lo que cuanto más alto mejor, aunque en la práctica debe ser limitado por cuestiones de memoria y tiempo de ejecución.

En lo que sigue se muestra cómo se ha abordado cada uno de los aspectos anteriores para el problema planteado.

Codificación de los individuos

El objetivo es encontrar el conjunto de parámetros que mejor ajusten una combinación fija de métodos, realizando para cada posible combinación una búsqueda o ajuste independiente del resto. Por tanto, se puede optar por individuos que sólo codifiquen el valor de los parámetros, estando el método al que pertenece el parámetro implícito en la posición que ocupa el valor en la cadena que constituye el individuo. En consecuencia, el espacio de búsqueda estará formado por todos los posibles valores de los parámetros de cada uno de los métodos que se considere en cada uno de los procesos de ajuste. En otras palabras, se ejecutará un ajuste basado en un algoritmo genético por cada combinación de métodos posible.

Asimismo se ha optado por codificar con valores reales, lo que permite reducir el tamaño de los individuos y simplificar el proceso de decodificación. Por consiguiente,

cada individuo o solución vendrá representado por un vector de valores reales con una componente por cada uno de los parámetros a ajustar en cada caso. Es decir que la longitud del individuo o cromosoma será variable dependiendo de la combinación, yendo desde un mínimo de 6 componentes hasta un máximo de 11 componentes. Ejemplos de todo esto se pueden ver en las figuras 4.29 y 4.30, donde se muestra la codificación de un individuo/solución para las combinaciones S1-E1-F2 y S2-E3-F2, respectivamente.

S1				E1	F2
1	2	3	4	5	6
r	g	b	$umbral$	$porcentaje$	$porcentaje$

Figura 4.29: Codificación para la combinación de métodos S1-E1-F2. En este caso cada individuo o cromosoma está formado por 6 genes

S1				E3			F1			
1	2	3	4	5	6	7	8	9	10	11
r	g	b	$umbral$	θ_1	θ_2	$porcentaje$	$radio$	It	θ_{limpia}	θ_{realza}

Figura 4.30: Codificación para la combinación de métodos S2-E3-F1. En este caso cada individuo o cromosoma está formado por 11 genes

Operadores de selección, cruce, mutación y parámetros asociados

En el proceso de búsqueda de un algoritmo genético hay dos factores clave: la diversidad de la población y la presión ejercida por la selección. Todos los ajustes que se hacen a la hora de diseñar el bucle principal del algoritmo genético (operadores genéticos y probabilidad de su aplicación, tamaño de la población, número de generaciones, etc.) no tienen otro propósito más que el de influir sobre estos dos factores de la forma más conveniente al proceso de búsqueda en el espacio de soluciones.

Por un lado, interesa mantener una diversidad de población muy elevada, para de este modo explorar lo más exhaustivamente posible el espacio de búsqueda, pero si no se controla este proceso de diversificación mediante alguna función de guiado hacia valores máximos de la fitness, el algoritmo no convergerá nunca, sino que simplemente irá dando saltos erráticos por el espacio de búsqueda.

4.2. Ajuste del procesamiento de imágenes mediante algoritmos genéticos

Por otro lado, si la presión ejercida sobre qué individuos seleccionar para formar la siguiente generación es demasiado grande, sólo se estará explorando una zona muy pequeña del espacio de búsqueda y al final todos los individuos acabarán siendo prácticamente iguales, siendo difícil salir de zonas de máximos locales.

Como se explicaba en (Sarle et al., 1993) con una analogía divertida y clara: *“Mantener una presión de selección leve y una diversidad alta es cómo tener a canguros borrachos esparcidos por todo el espacio de búsqueda (...), mientras que ejercer mucha presión es cómo matar a todos los canguros de un tiro y dejar sólo a uno, que al final se deprime porque está solo, y se niega a moverse”*.

En cuanto a los operadores es importante hacer las siguientes consideraciones:

- El **operador de selección** es el encargado de escoger qué individuos, de entre los que forman la población actual pasarán su material genético a la siguiente generación. Este operador debe mantener el equilibrio entre una selección de los mejores individuos y de algunos individuos no tan buenos, incluso “malos”, pero distintos del resto, con también matices aleatorios (Baker, 1987; Goldberg y Deb, 1991; Grefenstette, 1986; Kramer, 2008).
- El **operador de cruce** determina, dados dos o más progenitores, cómo se recombinan sus genes para formar sucesores. Puede ser aleatoriamente (favorece la diversidad) o guiado por la fitness de cada uno de los progenitores (mayor presión). A su vez, la **probabilidad de cruce** es la que establece la probabilidad de que los progenitores se crucen más de una vez (tengan sucesores distintos con más de un progenitor).
- La **función de mutación** altera los sucesores creados de forma totalmente aleatoria. Cuanto más alta sea la **probabilidad de mutación** más individuos serán mutados. Este operador favorece la diversidad pero también puede conducir a un proceso de búsqueda puramente aleatorio.

En la literatura hay un inmenso abanico de artículos que discuten y proponen cómo deben diseñarse los operadores de selección, cruce, mutación y cómo deben elegirse sus respectivas probabilidades para cada caso. Existen además un conjunto de operadores propuestos en numerosos trabajos que dan buenos resultados ante un gran número de

situaciones (Booker et al., 1989; Davis, 1987; Goldberg, 1989; Goldberg y Deb, 1991; Radcliffe y George, 1993). De este conjunto se escogieron los operadores usados en el presente trabajo: selección estocástica uniforme, cruce disperso y mutación gaussiana. Sus respectivas probabilidades también se seleccionaron utilizando los valores que se aconsejan en las referencias anteriores (fracción de cruce del 80 %, probabilidad de cruce del 70 %) salvo en el caso de la probabilidad de mutación, como se explica más adelante.

La función de selección estocástica uniforme se muestra en la figura 4.31. Para entender cómo funciona supongamos que el objetivo es encontrar el máximo de una función que en este tipo de problemas coincide con la fitness. Se tiene una población de 6 individuos con $fitness = [0.35, 0.20, 0.14, 0.13, 0.13, 0.05]$ y se quieren seleccionar 6 para la siguiente fase. Esta función selecciona los individuos de la siguiente forma: se crea un vector donde a cada individuo se le asignan tantas posiciones como peso tiene su fitness sobre el total ($fitness_i / \sum_{j=1}^N fitness_j$), y posteriormente se generan punteros con un espaciado uniforme y correspondiente a $1/6$ (número de individuos a seleccionar). Luego, se eligen los individuos a los que apunta cada uno de los punteros. En este caso, se seleccionarían los individuos [1, 1, 2, 3, 4, 6]. Es decir, dos veces el primero, el segundo, el tercero, el cuarto y el sexto. Esta función se comporta muy bien, ya que asegura que los mejores individuos tengan mayor representación a la vez que permite que pasen algunos de los peores (la probabilidad de escoger al menos uno de los peores individuos es alta).

Los operadores de cruce y mutación se representan en las figuras 4.32 y 4.33 respectivamente. El cruce disperso fusiona la información de los dos padres entremezclando los cromosomas de ambos de forma aleatoria, mientras que la mutación gaussiana añade valores aleatorios a cada uno de los genes obtenidos de una distribución gaussiana de media cero y varianza calculada en función de dos parámetros: *scale* y *shrink*. El parámetro *scale* determina la varianza de la primera generación y el parámetro *shrink* establece cómo se reduce la varianza en cada generación. Ambos valores se fijaron a 1, de modo que la varianza empieza en 1 y disminuye linealmente hasta alcanzar 0 en la última generación.

4.2. Ajuste del procesamiento de imágenes mediante algoritmos genéticos




Figura 4.31: Selección estocástica uniforme

Padre 1:	a	b	c	d	e	f	g	h
Padre 2:	1	2	3	4	5	6	7	8
Vector binario aleatorio:	1	1	0	0	1	0	0	0
Hijo:	a	b	3	4	e	6	7	8

Figura 4.32: Cruce disperso. Se crea aleatoriamente un vector binario y se seleccionan los cromosomas del progenitor 1 cuando el vector vale 1 y del progenitor 2 cuando el vector vale 0

Antes:	a	b	c	d	e	f	g	h
Sumandos aleatorios:	α	β	χ	δ	ϵ	φ	γ	η
Después:	$a + \alpha$	$b + \beta$	$c + \chi$	$d + \delta$	$e + \epsilon$	$f + \varphi$	$g + \gamma$	$h + \eta$

Figura 4.33: Mutación gaussiana. Consiste en añadir un valor aleatorio, obtenido de una distribución gaussiana, a cada gen

Fitness

Lo bien que funciona cada posible combinación de valores de los parámetros de cada método se mide en términos de la similitud estadística entre el resultado devuelto por la plataforma usando dichos valores y los valores reales. El valor real de mala hierba encontrada, asociado con cada imagen estudiada, se obtiene durante el muestreo, recogiendo muestras del terreno del área cubierta por mala hierba que coincide con la imagen tomada y analizando las muestras en el laboratorio, determinando la biomasa tal como se explicó en el capítulo 2.

Una vez conocida la biomasa de cada imagen, la *fitness* para cada individuo (solución) se estima calculando la correlación entre la biomasa y los valores de cobertura de malas hierbas obtenidos al aplicar la combinación de métodos y valores para los parámetros codificados en el individuo (solución) a toda la colección de imágenes de partida. Para calcular la correlación se ha optado por el coeficiente de Pearson, que mide el grado de asociación lineal entre dos variables medidas en escala de intervalo, tomando valores entre -1 y 1. Valores próximos a 1 indicarán una fuerte correlación lineal positiva, mientras que valores próximos a -1 indican una fuerte asociación lineal negativa (no contemplada en nuestro caso), y el 0 la falta absoluta de asociación lineal. Es decir, el coeficiente de correlación de Pearson medirá el parecido de los valores devueltos por la plataforma (utilizando la combinación de métodos y los valores para los parámetros codificados en el individuo que se está evaluando) con los valores de biomasa, en una escala de 0 a 1. Cada individuo es clasificado según su valor del coeficiente de Pearson y la población de posibles soluciones irá evolucionando hacia individuos (soluciones) que suministren mayores valores para el coeficiente de Pearson.

Generación de la población inicial

Para cada individuo dentro de la población, todos los valores de los genes se generan aleatoriamente al inicio dentro del rango $[-10 \dots 1000]$. Todos excepto los parámetros de **S1**, que se establecen también aleatoriamente pero cumpliendo las condiciones expresadas en la ecuación 4.2. Con esto se pretende evitar la exploración de zonas del espacio de búsqueda en las que se sabe que no existen soluciones válidas.

4.2. Ajuste del procesamiento de imágenes mediante algoritmos genéticos

Debido al gran coste computacional asociado al cálculo de la fitness (cada individuo, en cada generación, debe procesar más de 60 imágenes), se limitó la población a 30 individuos. Para contrarrestar los efectos negativos en la diversidad producidos por tener una población pequeña (poca representación del espacio de búsqueda), se ha utilizado un operador de elitismo en la selección (el mejor individuo de cada generación siempre sobrevive), junto con una probabilidad de mutación media/alta, 30 %. Como ya se comentó con un número elevado de mutaciones la probabilidad de visitar distintas zonas del espacio de búsqueda es mayor y se evita que la búsqueda quede estancada en máximos locales. Por otra parte, con el elitismo se asegura la convergencia del proceso de búsqueda y se aumenta la probabilidad de alcanzar el óptimo global (Rudolph, 1994). En otras palabras, el elitismo también garantiza que la solución final es la mejor de todas las soluciones exploradas durante toda la ejecución del AG.

Finalmente, se han establecido dos *condiciones de terminación* de la ejecución del AG: 1) encontrar un individuo (solución) con una fitness (coeficiente de correlación de Pearson) mayor que 0.99 o 2) no haber sufrido mejoras en la fitness en las últimas 100 generaciones.

Resultados

En la tabla 4.2 se muestran los resultados obtenidos con el algoritmo genético. La columna de la izquierda muestra la combinación de métodos usada en el ajuste y se puede observar que se cubren todas las posibilidades. Para el ajuste se han utilizado dos conjuntos de imágenes de cereal de invierno con distintas características de iluminación y textura del suelo. El primer conjunto contiene 71 imágenes pertenecientes a muestreos realizados en días nublados, mientras que el segundo contiene 64 imágenes pertenecientes a muestreos efectuados en días soleados. Para cada uno de los conjuntos de imágenes, se muestran los resultados para dos tipos de ajuste: 1) todos los parámetros se ajustan y por tanto los parámetros de **S1** se generan aleatoriamente cumpliendo las condiciones de las ecuaciones 4.2 y se ajustan con el AG como el resto y 2) los parámetros de **S1**, en concreto las constantes de la combinación lineal, se fijan a los valores propuestos por Woebbecke et al. (1995) ($r = -1, g = 2, b = -1$), valores empíricos aceptados como los mejores para segmentar la capa vegetal en imágenes naturales y en consecuencia utilizados en numerosos trabajos.

Combinación de métodos	Nublado (71 imágenes)		Soleado (65 imágenes)	
	<i>S1</i> con valores (r, g, b) propuestos en (Woebbecke et al., 1995)	<i>S1</i> con valores (r, g, b) ajuste genético	<i>S1</i> con valores (r, g, b) propuestos en (Woebbecke et al., 1995)	<i>S1</i> con valores (r, g, b) ajuste genético
S1-E1-F1	0.899	0.911	0.816	0.704
S1-E1-F2	0.896	0.915	0.693	0.728
S1-E1-F3	0.896	0.909	0.909	0.890
S1-E2-F1	0.917	0.896	0.541	0.754
S1-E2-F2	0.780	0.924	0.722	0.881
S1-E2-F3	0.810	0.957	0.729	0.837
S1-E3-F1	0.851	0.851	0.539	0.725
S1-E3-F2	0.801	0.952	0.550	0.908
S1-E3-F3	0.700	0.961	0.729	0.901
S2-E1-F1	—	0.894	—	0.650
S2-E1-F2	—	0.904	—	0.704
S2-E1-F3	—	0.772	—	0.788
S2-E2-F1	—	0.909	—	0.740
S2-E2-F2	—	0.918	—	0.834
S2-E2-F3	—	0.912	—	0.811
S2-E3-F1	—	0.890	—	0.650
S2-E3-F2	—	0.903	—	0.824
S2-E3-F3	—	0.924	—	0.867

Tabla 4.2: Resultados del sistema de estimación de cobertura en términos del coeficiente de correlación con los valores de biomasa para dos conjuntos de imágenes, después del ajuste de parámetros de los métodos mediante un algoritmo genético

4.2. Ajuste del procesamiento de imágenes mediante algoritmos genéticos

La tabla 4.3 muestra el tiempo medio de CPU empleado por cada combinación de métodos. La tabla 4.4 presenta tanto la complejidad computacional como el tiempo medio de CPU en cada método por separado. En el caso de **F1** el tiempo corresponde a una única iteración. Los tiempos han sido calculados como media sobre las 136 imágenes de entrenamiento disponibles, con un ordenador con CPU Pentium IV a 3.2Ghz y 1Gb de memoria RAM a 533Mhz, bajo el entorno de desarrollo Matlab 7.01 y el sistema operativo Windows XP. El estudio del tiempo medio empleado en la ejecución de una combinación de métodos y de la complejidad de cada método, ayuda a evaluar la conveniencia de utilizar los métodos propuesto e implementados como punto de partida en el desarrollo de técnicas de detección de malas hierbas en tiempo real.

Combinación de métodos Combinación de métodos	tiempo medio empleado por imagen (sec)
S1-E1-F1	8.088
S1-E1-F2	0.359
S1-E1-F3	0.468
S1-E2-F1	11.412
S1-E2-F2	0.396
S1-E2-F3	0.507
S1-E3-F1	14.348
S1-E3-F2	1.356
S1-E3-F3	1.468
S2-E1-F1	9.212
S2-E1-F2	1.109
S2-E1-F3	1.179
S2-E2-F1	10.738
S2-E2-F2	1.265
S2-E2-F3	1.396
S2-E3-F1	18.128
S2-E3-F2	2.461
S2-E3-F3	2.656

Tabla 4.3: Tiempo medio por imagen empleado para cada combinación de métodos

El ajuste con el AG muestra resultados muy satisfactorios, alcanzando un coeficiente

Método	Complejidad computacional	tiempo medio empleado por imagen (sec)
S1	$\Theta(M \times N)$	0.296
S2	$\Theta(M \times N)$	1.121
E1	$\Theta(N + M \times N)$	0.109
E2	$\Theta(2N + 4 * M \times N)$	0.503
E3	$\Theta(2N + 4 * M \times N \log N)$	1.214
F1	$\Theta(M \times N \times r^2 \times It)$	4.321
F2	$\Theta(M \times N)$	0.265
F3	$\Theta(3 * M \times N)$	0.625

Tabla 4.4: Complejidad computacional y tiempo medio empleado por cada método

medio de correlación con la biomasa del 84,7 % con picos de hasta el 96 %. El AG ajusta mejor las imágenes pertenecientes a días nublados (91 %) que las correspondientes a días soleados (79 %), resultados acordes con el hecho de que las imágenes soleadas presentan un mayor número de reflejos y sombras, siendo por tanto fácil que se produzcan fallos en la fase de segmentación y aparezca ruido en la imagen segmentada que influye en el buen resultado del resto de etapas de procesamiento.

Además, es importante señalar que los tiempos de ejecución necesarios para el procesamiento de las imágenes son pequeños, ya que a excepción de **F1**, la complejidad de los métodos propuestos en ningún caso supera el orden cuadrático sobre el tamaño de la imagen, resultando en tiempos medios de ejecución de 1.21s por imagen.

Las mejores combinaciones de métodos son S1-E3-F2 y S1-E3-F3, siendo capaces de ajustar ambos conjuntos de imágenes con un coeficiente de correlación del 93 % y 93,7 %. Teniendo en cuenta también el tiempo de ejecución, las combinaciones S1-E2-F2 y S1-E2-F3 tienen un comportamiento bueno con valores de correlación algo inferiores, del 89,7 % y 91 % respectivamente, pero invirtiendo casi medio segundo menos en procesamiento.

Finalmente, queda latente que ningún método es del todo determinante por sí solo, sino que es necesaria la correcta combinación de ellos. Se puede concluir que en general los métodos más complejos suelen dar mejor resultado, como cabía esperar; es el caso

4.2. Ajuste del procesamiento de imágenes mediante algoritmos genéticos

de **S1** frente a **S2** y de los métodos **E2** y **E3** frente a **E1**. La excepción a esto es **F1**, que no sólo funciona peor (ajuste más pobre) que **F2** y **F3**, sino que además tiene una complejidad mucho más elevada, por lo que se descartó y en el trabajo que se presenta en las siguientes secciones no se tiene en cuenta.

La tabla 4.2 muestra también que al usar **S1**, mantener fijo el valor de los coeficientes de la combinación lineal de los planos RGB con valores propuestos en Woebbecke et al. (1995) empeoran los resultados (76 % de correlación frente a un 87 %). Esto demuestra que existen valores mejores para estos parámetros (en combinación con la umbralización) que los usados habitualmente para la discriminación de la capa vegetal.

Asimismo, en un procesamiento como el propuesto, los valores utilizados para las constantes de la combinación lineal de los planos RGB por sí solos no son determinantes (una vez limitados dentro de los requisitos estipulados por las ecuaciones 4.2), sino que además deben ir acompañados del correcto ajuste del resto de parámetros para los métodos, sobre todo del umbral de binarización.

4.2.2. Ajuste mediante *NSGA-II*

Dado que cada parámetro puede tomar valores en un rango infinito y que el tiempo necesario para procesar conjuntos grandes de imágenes es muy elevado, el ajuste usando un algoritmo genético estándar, aún dando resultados muy satisfactorios, es una larga y ardua tarea. En los trabajos desarrollados y descritos en el apartado anterior, para cada ejecución del algoritmo genético fueron necesarias una media de 500 generaciones, dentro de las cuáles cada uno de los 30 individuos procesaba más de 60 imágenes a una media de 1.21s por imagen, es decir, 12 días de ejecución constante.

Debido a ello, se consideró la aplicación de algún otro tipo de algoritmo genético más rápido y directo. Se escogió el *Non-dominated Sorting Genetic Algorithm (NSGA-II)* (Deb et al., 2000, 2002), que optimiza el uso de memoria, es más rápido que los demás genéticos y además es multiobjetivo, permitiendo la inclusión de más factores en la optimización.

Una optimización multiobjetivo permite ajustar simultáneamente un conjunto de funciones habitualmente en conflicto entre sí. El proposito, en definitiva, es obtener

un *conjunto* de soluciones óptimas, con diferentes compromisos entre el valor de las distintas funciones objetivo. A este conjunto de óptimos se le conoce como el óptimo de Pareto.

Dadas m funciones objetivo $(f_1(x), f_2(x) \dots f_m(x))$ a minimizar, una solución x^* es óptimo de Pareto si para todo x en la región factible del problema, Ω , se cumple que $(\forall i \in m, f_i(x) = f_i(x^*))$ o que $(\exists i \in m | f_i(x) > f_i(x^*))$. Es decir, una solución x^* es óptimo de Pareto si no existe otra solución factible que sea mejor que x^* en alguna función objetivo sin empeorar los valores de alguna de las restantes.

Asociada a esta definición se introduce una relación de orden parcial denominada *dominancia*. Una solución, w , domina a otra, v , si $\forall i \in m, (f_i(w) \leq f_i(v))$, y se denota como $w \preceq v$. El conjunto de soluciones óptimas, P^* , a un problema multiobjetivo se compone de todas las soluciones *no dominadas*: $P^* = \{x^* \in \Omega \wedge \neg \exists x \in \Omega | x \preceq x^*\}$. Este conjunto es el denominado *conjunto óptimo de Pareto*. La región de puntos definida por P^* en el espacio de valores de las funciones objetivo se conoce como *frente de Pareto*: $FP^* = \{u = (f_1(x), f_2(x) \dots f_m(x)) | x \in P^*\}$.

La figura 4.34 muestra un ejemplo de la región de puntos en una minimización de dos funciones (f_1, f_2) . El frente de Pareto (en rojo) se situará sobre el borde inferior de la región de soluciones factibles Ω (en azul). Ante la ausencia de más información, es imposible decidir sobre ninguno de los óptimos de Pareto, ya que cada uno representa distintos compromisos entre las funciones objetivo. Por ello, el objetivo principal de un algoritmo de optimización multiobjetivo, además de ofrecer soluciones lo más cercanas a FP^* , es encontrar el mayor número de éstas, en otras palabras ofrecer la mayor diversidad posible de soluciones.

Haciendo un poco historia, los primeros métodos de optimización multiobjetivo, como por ejemplo los *Multi-criteria Decision Making Methods* (Triantaphyllou, 2000), sugerían la conversión del problema multiobjetivo a un problema monoobjetivo puntuando de distintas formas el compromiso entre funciones que la solución multiobjetivo representaba. El problema de estos métodos era que para ser capaces de obtener variedad de soluciones en el frente de Pareto, el algoritmo debía ejecutarse repetidas veces variando la función de puntuación de soluciones multiobjetivo.

Para resolver este inconveniente, en la década de los noventa y a principios de




Figura 4.34: Principales objetivos de una optimización multi-objetivo: encontrar el mayor número posible de soluciones cercanas al frente de Pareto

los 2000 se propusieron distintas aproximaciones de *algoritmos evolutivos multiobjetivo* (MOEAs en inglés), capaces de encontrar múltiples óptimos de Pareto en una única ejecución (Coello et al., 2002; Deb, 2001). Ejemplos de estos primeros algoritmos evolutivos son el algoritmo MOGA (Fonseca y Fleming, 1993), el algoritmo NPGA (Horn et al., 1994), o el algoritmo NSGA (Srinivas y Deb, 1995).

Todas estas técnicas tenían en común dos características: 1) la asignación de fitness según el nivel de *no-dominancia* de las soluciones y 2) la conservación de diversidad de soluciones dentro del mismo frente de *no-dominancia* mediante alguna función de selección.

El nivel de *no-dominancia* de una solución sobre un conjunto de soluciones Ψ mide la cantidad de veces que la solución no es dominada por alguna otra. Así, dado el conjunto de soluciones $\Psi \subseteq \Omega$, se pueden definir sobre él varios *frentes de no-dominancia*, formado cada uno de ellos por las soluciones situadas en el mismo nivel de no-dominancia, figura 4.35. En definitiva, se puede decir que el nivel de no-dominancia mide la cercanía de cada solución al frente de Pareto, dando por lo tanto una buena medida de la bondad de cada solución. A su vez, mantener diversidad en cada frente de *no-dominancia*

asegurará una exploración exhaustiva del espacio de soluciones.




Figura 4.35: Frentes de no-dominancia formados por una población de 17 individuos-solución sobre el conjunto factible de soluciones Ω . Cada frente está formado por las soluciones con mismo nivel de no-dominancia, que mide la cercanía de las soluciones al frente de Pareto

Todos estos métodos, aunque son capaces de encontrar múltiples soluciones dentro del frente de Pareto en una única ejecución, tenían una convergencia demasiado lenta. Varios estudios plantearon la necesidad de introducir operadores más eficaces. Por ejemplo en SPEA (Zitzler y Thiele, 1998) se demostraba la mejora en la convergencia al añadir operadores de elitismo.

En el año 2000 (Deb et al., 2000) presentaron el *NSGA-II*, una versión mejorada del algoritmo NSGA propuesto en (Srinivas y Deb, 1995), que mantenía e incluso mejoraba los resultados de NSGA pero con una convergencia mucho más rápida.

Desde entonces, el *NSGA-II* destaca por encima de los demás métodos por su mejor implementación tanto del método de ordenación según el nivel de no-dominancia, como del método de cálculo de diversidad de cada solución.

Una rápida ordenación por orden de no-dominancia

La ordenación por nivel de *no-dominancia* es una tarea muy costosa, que necesita $\Theta(M \times P^3)$ comparaciones, donde P es el tamaño de la población y M el número de funciones objetivo. Dada una solución, se necesitan $M \times P$ comparaciones para calcular su nivel de no-dominancia. Este proceso se repite P veces (para cada solución), dando lugar al primer frente de no-dominancia. Posteriormente, se excluyen las soluciones situadas en el primer frente y se repite el proceso. Dado que en el peor de los casos puede haber tantos frentes como soluciones (cada frente estando formado por una única solución), el proceso puede repetirse otras P veces, llevando a una complejidad en el orden de $\Theta(M \times P^3)$.

Sin embargo, el método de ordenación usado por *NSGA-II* y detallado en la figura 2, asegura una complejidad máxima $\Theta(M \times P^2)$, reduciendo el número de comparaciones gracias a la comparación de cada solución con una población auxiliar P' , formada en cada momento por los potenciales candidatos de cada frente de no-dominancia.

Distancia de *crowding*, para la medición de la diversidad de soluciones

El *NSGA-II* utiliza una técnica denominada *crowding* (amontonamiento), que se encarga de asignar a cada individuo un valor asociado a la diversidad que representa su solución dentro de su frente de no-dominancia.

La distancia de *crowding* se define como la distancia media de una solución i con respecto a las dos soluciones más cercanas dentro de su mismo frente de no dominancia, $(i - 1$ y $i + 1)$, figura 4.37. Es evidente que esta distancia da una medida muy buena de la diversidad representada por la solución, ya que la distancia será mayor cuanto más alejadas se encuentren entre sí las soluciones del frente.

La figura 4.38 muestra la estructura principal del *NSGA-II* (Deb et al., 2000, 2002), apreciándose todos los elementos anteriormente explicados: ordenamiento basado en nivel de *no-dominancia*, evaluación de la diversidad mediante la técnica de *crowding* y selección basada en ambos valores. La selección se lleva a cabo eligiendo los individuos de mayor diversidad de entre los que pertenecen a los mejores frentes de no-dominancia, sin necesidad de especificar ningún parámetro mas que el porcentaje de individuos a

```

P' = Encuentra-frente-no-dominancia(P);
P' = 1; // Incluye el primer miembro en P'
// Una solución a la vez
para cada p ∈ P ∧ p ∉ P' hacer
    P' = P' ∪ p; // Incluye temporalmente p en P'
    // Compara p con los otros miembros de P'
    para cada q ∈ P' ∧ q ≠ p hacer
        si p ≺ q entonces
            P' = P' - q; /* Si p domina a un miembro de P', se quita el
                           miembro de P' */
        fin si
    sino si q ≺ p entonces
        P' = P' - p; /* Si p es dominado por algún miembro de P', p
                       no es incluido en P' */
    fin si
fin para
fin para

```

Figura 4.36: Estructura de la rápida ordenación según nivel de no-dominancia implementada en NSGA-II (Deb, 2001)




Figura 4.37: Cálculo de la distancia de crowding en una optimización con dos funciones objetivo

seleccionar, normalmente situado en 50 %.

Para usar *NSGA-II* en el ajuste del procesamiento de imágenes, y aprovechando que se pueden definir varias funciones objetivo se añadió como segundo objetivo el tiempo de procesamiento, además de la correlación con la biomasa (primer objetivo). Como ya se explicó antes, es importante encontrar un procesamiento que no sólo sea capaz de discriminar satisfactoriamente entre malas hierbas, cultivo y suelo, sino que lo haga en el menor tiempo posible, pensando tanto en un futuro procesamiento en tiempo real como en facilitar y acelerar el uso de la plataforma. La minimización del tiempo de procesamiento como segunda función objetivo cumple el requisito de estar en contraposición con la primera función objetivo (coeficiente de Pearson entre biomasa y cobertura de malas hierbas calculada), ya que los procesamientos más rápidos se corresponden con los métodos más sencillos, que en principio obtienen peores resultados, como se vio en el apartado anterior al realizar el ajuste mediante un algoritmo genético estándar.

Ahora bien, como las diferencias en tiempo de procesamiento vienen marcadas por el uso de uno u otro método dentro de cada etapa, siendo despreciables si se usa la misma combinación de métodos, para optimizar el tiempo de procesamiento hay que

```

 $t \leftarrow 0$ ;
Genera  $P(t)$ ;
mientras no condición terminación hacer
     $H(t) \leftarrow \text{crea-hijos}(P(t))$  ; /* Usa selección, cruce y mutación para
    crear descendientes */
     $R(t) \leftarrow P(t) \cup H(t)$ ; // Combina progenitores y descendientes
     $\mathcal{F} \leftarrow \text{Ordenación-no-dominancia}(R(t))$  ; /*  $\mathcal{F} = (\mathcal{F}_1, \mathcal{F}_2 \dots)$  todos los
    frentes no-dominados de  $R(t)$  */
     $P(t+1) \leftarrow \emptyset$ ;
     $i \leftarrow 1$ ;
    // Hasta que la población de progenitores esté completa
    mientras  $|P(t+1)| + |\mathcal{F}_i| \leq \text{Tamaño Población}$  hacer
        Calcula-distancia-crowding( $\mathcal{F}_i$ ) ; /* Calcula la distancia de
        crowding (diversidad) */
         $P(t+1) \leftarrow P(t+1) \cup \mathcal{F}_i$  ; /* Incluye el frente no-dominado
        i-ésimo en la población de progenitores */
         $i \leftarrow i + 1$ ; // Siguiendo frente
    fin mientras
    Ordena-por-distancia-crowding( $\mathcal{F}_i$ ) ; /* Ordena según distancia
    crowding en orden descendente */
     $P(t+1) \leftarrow P(t+1) \cup \mathcal{F}_i[1 : (\text{Tamaño Población} - |P(t+1)|)]$  ; /* escoge
    los primeros  $(\text{Tamaño Población} - |P(t+1)|)$  elementos de  $\mathcal{F}_i$  */
     $H(t+1) \leftarrow \text{crea-hijos}(P(t+1))$  ; /* Usa selección, cruce y mutación
    para crear descendientes */
     $t \leftarrow t + 1$ ; // Siguiendo generación
fin mientras

```

Figura 4.38: Estructura del Non-dominated Sorting Genetic Algorithm-II, NSGA-II (Deb et al., 2000, 2002)

4.2. Ajuste del procesamiento de imágenes mediante algoritmos genéticos

realizar el ajuste sobre todas las posibles combinaciones de métodos a la vez, dejando que la selección de la mejor combinación de métodos a usar sea también un resultado del algoritmo genético. En este caso es posible abordar el problema con esta estrategia gracias al uso más eficiente que hace *NSGA-II* de la memoria, que permite manejar más información a la vez sin bloqueos en el procesamiento.

La figura 4.39 muestra la nueva codificación de los individuos, que contienen 17 genes: los tres primeros indican la combinación de métodos a usar, y todos los demás codifican los parámetros de **todos** los métodos de procesamiento. Nótese que no se ha considerado en el ajuste el método **F1** por haber suministrado muy malos resultados en los ajustes con el algoritmo genético estándar.

Comb.			S1				S2		E1	E2		E3			F2	F3
1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17
<i>S</i>	<i>E</i>	<i>F</i>	<i>r</i>	<i>g</i>	<i>b</i>	<i>umb</i>	luc	somb	porc	x	m	θ_1	θ_2	<i>porc</i>	porc	porc

Figura 4.39: Codificación de los individuos al usar *NSGA-II*. La combinación de métodos es variable. Cada individuo contiene 17 genes

En el ajuste se utilizó el mismo conjunto del caso anterior, de 136 imágenes de cereal de invierno separadas en dos conjuntos (Nublado y Soleado). Cada individuo, para cada generación, procesa todas las imágenes del conjunto usando la configuración codificada en sus genes (combinación de métodos a usar y el valor de los parámetros), obteniendo un valor de cobertura de mala hierba correspondiente a cada imagen. La primera función objetivo es la misma que la fitness del genético estándar, maximizar el coeficiente de Pearson entre los valores de cobertura de infestación estimados y los valores biomasa asociada a cada imagen. La segunda función objetivo consiste en minimizar el tiempo empleado (determinado para cada individuo al acabar el procesamiento).

Aparte de la codificación de los individuos y las funciones objetivo, los únicos parámetros que hay que establecer al usar *NSGA-II* es el tamaño de la población y los criterios de parada. El tamaño de la población, otra vez gracias al mejor uso de la memoria que hace *NSGA-II*, se aumentó a 80 individuos. Como condiciones de parada se utilizaron las mismas que en el caso del algoritmo genético estándar, es decir encontrar un individuo con un coeficiente de correlación de Pearson mayor que 0.99 o no haber sufrido mejoras en las 100 últimas generaciones.

La figura 4.40 muestra el resultado del ajuste mediante *NSGA-II* sobre ambos conjuntos de imágenes (nublado y soleado). Se muestra la población final como par de valores $(f2, f1)$, donde $f2$ representa el tiempo de procesamiento medio por imagen y $f1$ se define como $1 - \text{Pearson}$ (para minimizar en lugar de maximizar, ya que ambas funciones objetivo deben optimizarse en el mismo sentido). Los círculos muestran los conjuntos de individuos más destacados de cada ajuste, en términos de mejor $f1$ (círculo azul), siguiente mejor $f1$ dentro del siguiente rango de tiempos (círculo amarillo), mejor $f2$ (círculo magenta) y siguiente mejor $f2$ dentro del siguiente rango de correlación (círculo cian).

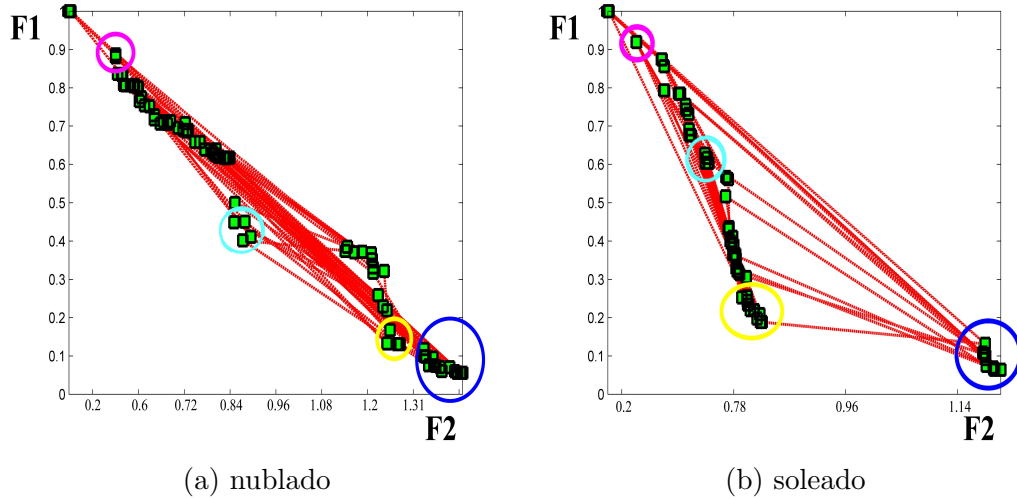


Figura 4.40: Resultados del ajuste mediante *NSGA-II*. El círculo azul representa la mejor $f1$, el círculo amarillo la siguiente mejor $f1$ dentro del siguiente rango de tiempos, el círculo magenta la mejor $f2$ y el círculo cian la siguiente mejor $f2$ dentro del siguiente rango de correlación

La tabla 4.5 muestra un resumen de los resultados del ajuste mediante *NSGA-II*. Al igual que en el ajuste con genético, se confirma que las mejores combinaciones son S1-E3-F2 (soleado) y S1-E3-F3 (nublado). S1-E3-F2 ajusta las imágenes soleadas con un coeficiente de correlación con la biomasa de 93,4% empleando una media de 1.4s por imagen. S1-E3-F3 ajusta las imágenes nubladas con un coeficiente de correlación con la biomasa de 97% empleando una media de 1.33s por imagen. Las siguientes combinaciones con mejores resultados son una vez más S1-E2-F2 (soleado) y S1-E2-F3 (nublado), alcanzando coeficientes de correlación algo inferiores (82,4% sobre las

4.2. Ajuste del procesamiento de imágenes mediante algoritmos genéticos

imágenes nubladas y 91,4 % sobre las imágenes soleadas respectivamente) invirtiendo a cambio entre 0.2 y 0.6s segundos menos en el procesamiento de la imagen.

Nublado (71 imágenes)			
	Coeficiente Pearson	Tiempo medio por imagen	Métodos usados
Mejor f1	0.970	1.334	S1-E3-F3
Segundo mejor f1	0.914	1.132	S1-E2-F3
Mejor f2	0.086	0.312	S1-E1-F2
Segundo mejor f2	0.635	0.84	S1-E1-F3
Soleado (65 imágenes)			
	Coeficiente Pearson	Tiempo medio por imagen	Métodos usados
Mejor f1	0.934	1.406	S1-E3-F2
Segundo mejor f1	0.824	0.835	S1-E2-F3
Mejor f2	0.099	0.301	S1-E1-F2
Segundo mejor f2	0.394	0.532	S1-E1-F3

Tabla 4.5: Resultados del ajuste mediante *NSGA-II*

La combinación más rápida es siempre S1-E1-F2, empleando aproximadamente 0.3s por imagen, pero con pésimos resultados en la discriminación, no siendo capaz de alcanzar ni tan siquiera el 10 % de coeficiente de correlación con la biomasa. La siguiente combinación con alta velocidad de procesamiento es S1-E1-F3, que emplea entre 0.55 y 0.84s por imagen, alcanzando coeficientes de correlación bajos (63,5 % en nublado y 39,4 % en soleado). Es evidente que las combinaciones de métodos más complejas (y por lo tanto más lentas) demuestran ser las que funcionan mejor. También se corrobora que las imágenes soleadas son más difíciles de ajustar.

En lo que se refiere al método de ajuste utilizado, *NSGA-II* alcanzó una correlación media con la biomasa sobre ambos conjuntos del 89,4 %, mejorando los resultados del genético en un 5 % y logrando estos valores en tan sólo 300 generaciones, lo que significó aproximadamente 86 horas menos para cada ejecución. Si además tenemos en cuenta que sólo fueron necesarias dos ejecuciones (una sobre cada conjunto, Nublado y Soleado), frente a las 24 realizadas con el algoritmo genético estándar (no se contabilizan

las combinaciones que contenían el método **F1**), significa haber reducido el tiempo de ejecución en un 94,2 % para realizar el ajuste. Además, el incluir como objetivo el tiempo de cómputo permite determinar cuales son las combinaciones que requieren un tiempo menor en el procesamiento, de gran interés para determinar los porcentajes de mala hierba, cultivo y suelo en tiempo real.

El ajuste efectuado por los genéticos no sólo ha servido para encontrar qué combinación de métodos y valor de sus parámetros son los mejores en media dado un conjunto de imágenes, sino que ha permitido analizar exhaustivamente el funcionamiento de cada uno de los métodos propuestos y su respuesta ante diferentes condiciones. Además, los resultados logrados sobre conjuntos grandes de imágenes señalan claramente el buen funcionamiento de la plataforma, ya que los valores obtenidos han conseguido picos de correlación del 97 % con los valores de la biomasa, utilizados como patrón y representativos de la situación real.

Por último, los resultados alcanzados todavía dejan margen de mejora, ya que como se ha visto, ningún método es determinante por sí sólo, sino que deben combinarse adecuadamente. La tabla 4.6 presenta para cada método qué características de la imagen son las que parecen determinar la obtención de unos buenos resultados y cuáles son las ventajas e inconvenientes de cada uno de las aproximaciones propuestas. A partir de una caracterización de la imagen, podría ser interesante desarrollar algún procedimiento capaz de escoger los mejores métodos y valores de los parámetros teniendo en cuenta las características de la imagen a tratar. Todo esto conduce a la aproximación que se explica en la sección 4.3, que permite obtener la cobertura de infestación, cultivo y suelo con mayor precisión.

4.3. Ajuste del procesamiento en función de las características de cada imagen. Un sistema de razonamiento basado en casos

El ajuste mediante algoritmos genéticos, sección 4.2, permite encontrar combinaciones de métodos y valores para los parámetros que funcionan bien sobre un conjunto grande de imágenes. Estos valores pueden ser posteriormente usados en la plataforma

4.3. Ajuste del procesamiento en función de las características de cada imagen

Método	Variables decisivas	Ventajas	Inconvenientes
S1	Iluminación	Robusto	Parámetros difíciles de ajustar
S2	”	Parámetros fáciles de ajustar	Dependiente de la naturaleza de la imagen
E1	Errores de sembrado Homogeneidad y diferencias en el estado de crecimiento	Robusto frente a errores de sembrado Muy rápido	No es robusto frente a imágenes no homogéneas Pobres resultados medios
E2	”	Robusto frente a imágenes no homogéneas	Parámetros difíciles de ajustar No es robusto frente a errores de sembrado
E3	”	Muy Robusto frente a todo tipo de imágenes	Parámetros difíciles de ajustar Lento
F2	”	Muy rápido No es robusto al ruido	Parámetros difíciles de ajustar
F3	”	Robusto al ruido	Parámetros difíciles de ajustar

Tabla 4.6: Ventajas e inconvenientes de cada método de procesamiento

de procesamiento de imágenes desarrollada como valores por defecto, mejorando considerablemente los resultados cuando se procesan nuevas imágenes. Tener un sistema fijo que funciona bien para conjuntos grandes y variados de imágenes, es, sin lugar a duda, algo deseable y muy útil. Ahora bien, ¿por qué tener un sistema fijo en lugar de uno variable? Al usar la plataforma, es evidente que muchas veces el ajuste *global* encontrado por los algoritmos genéticos funciona bien, pero podría realizarse un ajuste más fino adaptado a las características de cada imagen de entrada.

Si se definen y catalogan cuáles son las distintas características que pueden presentar las imágenes, y cómo debe el procesamiento tener en cuenta las mismas, podría pensarse en procesamiento que varíe dependiendo de la naturaleza de la imagen a procesar. Disponer de esta posibilidad significaría además lograr automatizar por completo el proceso de estimación de las coberturas de malas hierbas, cultivo y suelo en una imagen.

Como se explicó en el apartado 4.2, es muy complicado determinar el mejor valor de los parámetros y la mejor combinación de métodos sobre conjuntos grandes de imágenes incluso siendo un usuario experto. Ahora bien, lo que sí puede hacer un experto es ajustar el procesamiento, partiendo de un conjunto de métodos y parámetros inicialmente aceptables sobre una única imagen basándose principalmente en lo que ve (las características de la imagen) y su experiencia.

La herramienta de ajuste variable que se propone debería emular precisamente este comportamiento, es decir, dada una nueva imagen, y basándose en experiencias anteriores, mejorar el procesamiento de partida para que los resultados sean óptimos.

Dentro de la IA, este tipo de sistemas que emulan la toma de decisiones de un experto humano se conocen como *Sistemas Expertos* (Rich y Knight, 1991). Estos sistemas suelen tomar decisiones mediante reglas de producción u otros procesos de razonamiento, utilizando conocimiento global sobre el dominio, extraído de la experiencia de los expertos humanos (Pajares y Santos, 2005).

El conocimiento se puede adquirir de forma automática utilizando alguna técnica de *Aprendizaje Automático*, que permite inferir el mismo almacenándolo en estructuras como reglas de producción, árboles de decisión, etc. Los métodos de aprendizaje son muchos y variados, pudiéndose dividir por categorías dependiendo del tipo de elementos a aprender y de cómo se aprenden, como por ejemplo el aprendizaje supervisado, el

4.3. Ajuste del procesamiento en función de las características de cada imagen

aprendizaje no supervisado, el aprendizaje por analogías, por refuerzo, etc. (Mitchell, 1997).

En este caso, el propósito es obtener un sistema que utilice las experiencias anteriores. Es decir, al igual que hace el experto humano, el sistema debe procesar imágenes comparando la similitud de éstas con imágenes que ya fueron procesadas anteriormente con éxito. A este tipo de aprendizaje que compara una situación actual con situaciones pasadas, se le denomina en inglés *Instance-based learning*. El máximo exponente dentro de este tipo de aprendizaje, tanto que muy a menudo en la literatura se confunden, es el usado en el *Razonamiento Basado en Casos* (CBR) (Aamodt y Plaza, 1994; Leake, 1996; Lenz et al., 1998; López de Mántaras et al., 2005; Sierra-Araujo, 2006). El CBR no es un método de aprendizaje puro, sino que, como su nombre indica, es un sistema de razonamiento completo, que además incorpora tareas de aprendizaje.

Un CBR resuelve nuevos problemas adaptando las soluciones que fueron usadas para solucionar problemas antiguos, (Riesbeck y Schank, 1989). El CBR es una alternativa a los sistemas expertos clásicos basados en reglas que soluciona el principal cuello de botella de éstos: la obtención del conocimiento. Para un experto es más fácil plasmar su conocimiento describiendo casos y explicando cómo resolverlos que definiendo reglas globales de solución al problema, un proceso de inducción mucho más complejo. Más aun, siempre es más sencillo añadir nuevos casos y su solución asociada que inferir nuevas reglas a partir de casos nuevos (Leake, 1996).

El CBR encuentra la(s) experiencia(s) pasada(s) más similares al problema actual (caso nuevo) y adapta la solución tomada del caso antiguo al nuevo caso. El ciclo estándar está compuesto por cuatro etapas (Aamodt y Plaza, 1994), tal y como se muestra en la figura 4.41.

1. **Recuperación:** El sistema busca en la *Base de Casos*, que contiene todos los casos previos, cuál de ellos es el más similar al nuevo caso de entrada, usando para ello algún método de cálculo de similitud entre casos. Al caso previo más similar se le denomina *caso recuperado*. Los métodos de cálculo de similitud usados varían ampliamente en función del tipo de casos. Puede calcularse similitud por la *superficie* o contenido de los casos (pares atributo-valor), por su estructura (casos representados por estructuras complejas como grafos o árboles), o deri-

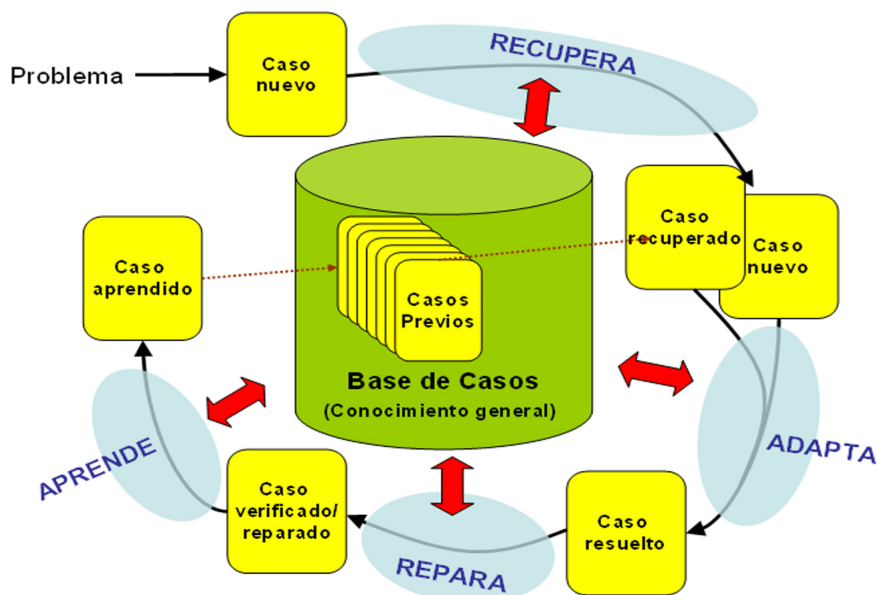


Figura 4.41: El ciclo CBR

vando características descriptivas de cada caso a partir de inferencias basadas en conocimiento sobre el dominio (López de Mántaras et al., 2005).

2. **Adaptación:** Se adapta la solución que fue tomada para el caso recuperado al nuevo caso, mediante algún método de adaptación llevando como resultado al *caso resuelto*. En situaciones donde los problemas planteados por el nuevo caso y el caso recuperado son muy similares, la adaptación puede ser tan sencilla como reutilizar la misma solución, sin cambios. Sin embargo, cuando los problemas plantean diferencias significantes, habrá que adaptar la solución decidiendo qué cambiar y cómo cambiarlo. Las tres formas de adaptación más comunes son mediante *sustitución*, donde se cambian partes de la solución recuperada, por *transformación*, que altera la estructura de la solución y mediante *adaptación generativa*, donde se repite el proceso de generación de la solución a partir del nuevo problema (López de Mántaras et al., 2005).
3. **Reparación/Verificación:** Se comprueba si la solución adoptada por el caso resuelto es suficientemente buena, y en caso negativo se repara. En la inmensa

4.3. Ajuste del procesamiento en función de las características de cada imagen

mayoría de los casos, la reparación consiste en una nueva adaptación cambiando alguno de los parámetros, aunque puede también implicar volver a efectuar el ciclo desde el principio, cambiando por ejemplo el método de cálculo de similitud para recuperar un caso distinto.

4. **Aprendizaje:** El caso resuelto y reparado se almacena en la base de casos, enriqueciendo el conocimiento del sistema. En algunas situaciones, sin embargo, el caso no aporta información relevante (por ejemplo si presenta un problema prácticamente idéntico al de un caso ya existente), no siendo aconsejable su almacenamiento, sobre todo si se tiene en cuenta que el número de casos almacenados en la base de casos influye negativamente sobre la eficiencia global del sistema debido al número de comparaciones necesarias en la etapa de recuperación. En este contexto aparece el concepto de *mantenimiento* de la base de casos, formado por todas aquellas técnicas orientadas a mantener en todo momento una base de casos variada y completa pero utilizando el menor número de casos posible. Así, puede decidirse no almacenar un caso, almacenar sólo parte, o incluso hacer limpieza de casos previos irrelevantes, como por ejemplo aquellos que no han sido recuperados nunca.

La resolución de problemas mediante sistemas de CBR funciona bien en problemas en los que la experiencia es un factor fundamental en la resolución, es decir, en problemas donde casos similares se resuelven de forma similar, y donde el aprendizaje de nuevas experiencias es esencial para mejorar la eficacia del sistema. Un ejemplo es el sistema **CASEY** (Koton, 1988), capaz de hacer diagnósticos médicos, partiendo de la hipótesis de que pacientes de características similares y con los mismos síntomas deben ser tratados de forma similar.

A la hora de procesar imágenes, en algunos casos cabe esperar que imágenes similares deban ser procesadas de forma similar. Es decir, un procesamiento que dio resultados óptimos en una imagen dará buenos resultados también sobre cualquier imagen similar, llevando claramente a la aplicación de CBR. Es más, cuando las imágenes presentan una alta variabilidad entre sí, aplicar métodos estándares basados en conocimiento global sería impensable (Perner, 2001).

A la hora de aplicar CBR a un procesamiento de imágenes, hay muchas posibles

estrategias a seguir (Perner, 1998). En Grimnes y Aamodt (1996), se propone una arquitectura CBR genérica para el tratamiento de imágenes médicas, combinando análisis de alta abstracción (características concretas) y análisis de baja abstracción (píxel a píxel), donde cada parte de la arquitectura está organizada como tareas de ingeniería del conocimiento, de forma que dicha arquitectura pueda ser reutilizada por cualquier sistema de procesamiento de imágenes. En Perner (2006) se propone un sistema CBR para el reconocimiento de objetos donde los casos almacenan la forma de distintos tipos de bacterias, de modo que una imagen de entrada se divide para posteriormente analizar cada segmento de la imagen buscando reconocer algo parecido al contenido de la base de casos. En Perner (1999) el sistema CBR descrito tiene que determinar el mejor umbral en la segmentación de imágenes de radiografías cerebrales. El autor propone almacenar en los casos, además de la imagen y el valor de umbral usado, características de la naturaleza de la imagen que no están contenidas explícitamente en ella, como las condiciones en las que fue tomada.

A pesar de los varios casos de aplicaciones de CBR sobre imágenes, hasta la fecha y hasta donde se ha podido investigar, nadie había propuesto la aplicación de un CBR para ayuda en el procesamiento de imágenes naturales, como el CBR aquí descrito y publicado en Burgos-Artizzu et al. (2009b).

4.3.1. Arquitectura del sistema

El sistema CBR tiene que decidir para cada imagen de entrada el mejor método a usar en cada etapa del procesamiento y el valor de los parámetros, a partir de la similitud con uno de los casos almacenados. Una vez decidido esto, el sistema procesará la imagen y almacenará los resultados obtenidos. Para evaluar el funcionamiento del sistema CBR desarrollado, al igual que con el ajuste mediante algoritmos genéticos, se ha contrastado la estimación de cobertura de infestación para cada imagen con el valor de biomasa recogido en cada punto, simultáneamente al muestreo fotográfico.

El CBR sigue un ciclo clásico sin validación (Recuperación-Reutilización-Aprendizaje), incluyendo al principio una clasificación por indexación de los casos, figura 4.42. Los casos están almacenados en clases disjuntas, que representan conjuntos de imágenes con características similares. Con la indexación se obtiene la clase de imágenes con ca-

4.3. Ajuste del procesamiento en función de las características de cada imagen

racterísticas similares a la imagen de entrada. Luego, el sistema recupera el caso de la clase que presenta un mayor grado de similitud, usando técnicas de análisis de similitud entre imágenes. Una vez recuperado el caso, el sistema procesa la imagen de entrada asociada a la consulta, usando el mismo conjunto de métodos y valores de parámetros que se usó en el caso recuperado, obteniendo la estimación de tantos por ciento de suelo, cultivo e infestación para la imagen de entrada. Por último, el sistema puede aprender de este nuevo caso, incluyéndolo en la base de casos cuando lo considera necesario.

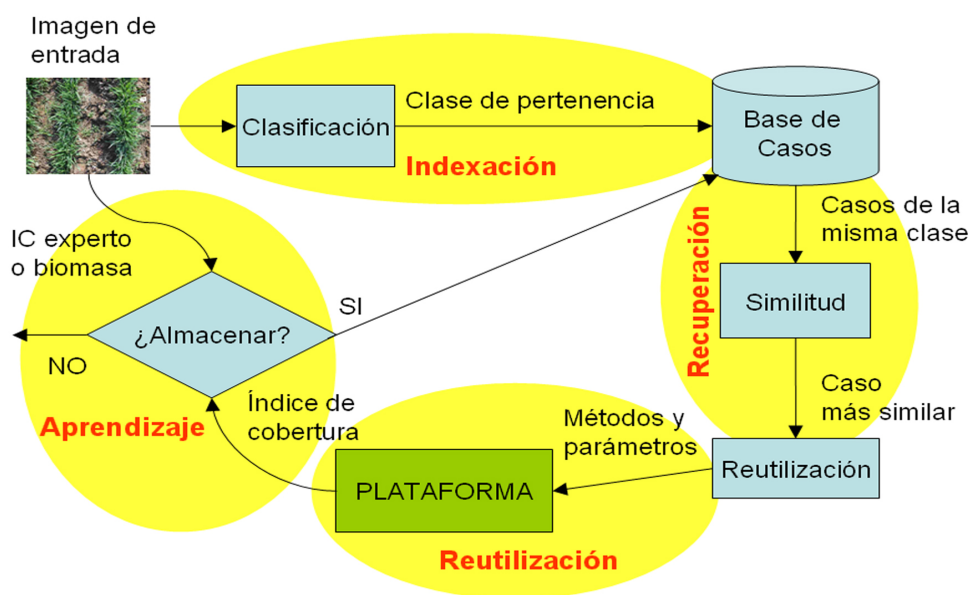


Figura 4.42: Arquitectura del sistema CBR propuesto

4.3.2. Indexación de los casos

No es viable comparar cada nueva consulta con todas las imágenes de la base de casos, ya que cada una tiene como mínimo 3 millones de píxeles, y la complejidad de los métodos de cálculo de similitud necesitan por lo menos una exploración completa de la imagen. Para evitar esto, cada imagen se clasifica en una serie de clases disjuntas, donde cada clase representa condiciones similares ante un conjunto de atributos considerados característicos. De este modo, el número de casos con los que se compara cada consulta

se reduce considerablemente, ya que sólo se comparará con los de su misma clase.

La tabla 4.6 presentaba, para cada etapa del procesamiento de imágenes, cuáles son las características decisivas para la obtención de buenos resultados usando uno u otro método. Así, la iluminación juega un papel fundamental en el método usado de segmentación, mientras que la homogeneidad de las imágenes (densidad de malas hierbas y cultivo) afecta a las etapas de eliminación y filtrado, y la presencia de errores de sembrado hace que sea preferible el uso, en la etapa de eliminación, del método **E1**. Dado que el objetivo de la indexación es separar las imágenes en clases disjuntas para las cuales el procesamiento base sea el mismo, la cuestión ahora es establecer qué características son las determinantes. A partir de la experiencia adquirida en la utilización de los métodos de procesamiento propuestos sobre un gran conjunto de imágenes, se observa que los siguientes atributos son útiles en la caracterización de una imagen:

- Iluminación (Sol o Nubes)
- Presencia de error en el sembrado (Sí o No)
- Estado de crecimiento del cultivo (Bajo, Medio, Alto)
- Zona infestada (Sí o No)

Teniendo en cuenta los posibles valores para este conjunto de atributos, se pueden tener 24 posibles clases ($2 \times 2 \times 3 \times 2$). Sin embargo, de estas 24 clases, sólo 14 representan situaciones posibles. El resto son combinaciones con casos contradictorios, por ejemplo error en el sembrado y a la vez infestación. En la figura 4.43 se muestran tachadas por una cruz las clases que no son factibles.

La asignación (automática) de valores a cada uno de los atributos que caracterizan una imagen se realiza del siguiente modo:

Iluminación: Se determina transformando la imagen RGB de entrada a una imagen HSI, y posteriormente calculando el valor del histograma de la componente I (intensidad) para el máximo valor de intensidad (255). Si este valor sobrepasa un umbral

4.3. Ajuste del procesamiento en función de las características de cada imagen

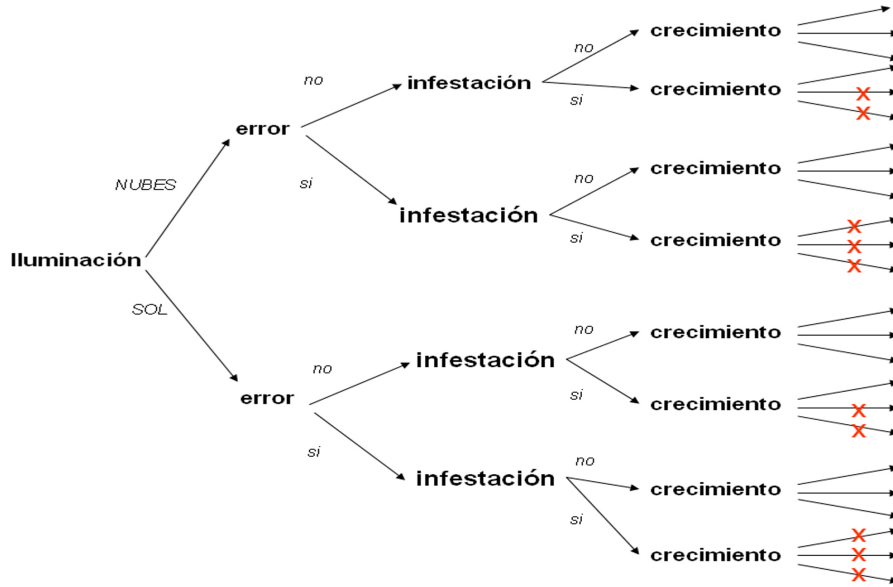


Figura 4.43: Clases de pertenencia. Las clases no factibles se muestran marcadas con una cruz roja

quiere decir que la imagen fue tomada con mucha luz (muchos píxeles presentan máxima intensidad debido a que la luz ha saturado el sensor) y por lo tanto pertenece a un día soleado, en caso contrario, se trata de un día nublado (figura 4.44). El umbral se ha fijado en 12000, a partir de la observación de un conjunto de 100 imágenes nubladas y soleadas elegidas aleatoriamente. Éstas presentaban valores dispares en el número de píxeles con una intensidad de 255, fluctuando en el intervalo [15000, 19000] en el caso de las imágenes soleadas y en [2000, 6500] en el caso de las nubladas.

Estado crecimiento: Se calcula en función de la proporción de píxeles eliminados usando el método de eliminación **E2**. Bajo si $\text{proporción} < 30\%$, medio si $30\% \leq \text{proporción} \leq 55\%$ y alto si $\text{proporción} > 55\%$ (figura 4.45). Estos valores de umbral se han establecido analizando visualmente un conjunto de 100 imágenes que cubrían todos los casos.

Error de sembrado: Se calcula en función de la proporción de columnas con valor similar a la altura de la imagen, y dependiendo también del estado de crecimiento




Figura 4.44: El valor del histograma para el valor máximo de intensidad de la componente I de una imagen indica si ésta fue tomada en un día soleado, debido a la saturación producida por la luz sobre el sensor. Soleado si el número de píxeles a 255 > 12000 o Nublado si ≤ 12000 .

previamente calculado, ya que cuando el estado de crecimiento es alto cabe esperar una proporción más alta que cuando es bajo, tal y como se muestra en la tabla 4.7, y la figura 4.46. Los valores de umbral se han determinado analizando visualmente un conjunto de 100 imágenes que cubrían todos los casos posibles.

	Estado de crecimiento		
	Bajo	Medio	Alto
Error en el sembrado si	proporción $< 12\%$	proporción $< 14\%$	proporción $< 18\%$

Tabla 4.7: Cálculo de la existencia de errores de sembrado en función de la proporción de columnas en la imagen con número de píxeles de vegetación iguales a la altura de la imagen y el estado de crecimiento

Infestado: Se considera como infestada una imagen si después de la segmentación más del 80 % de los píxeles son blancos (vegetación), tal y como se muestra en la figura 4.47.

El cálculo de estos atributos se efectúa previamente a la ejecución del sistema, sobre todas las imágenes disponibles y el resultado se almacena en una tabla. Cuando la imagen introducida como caso nuevo es una imagen ya conocida, se consulta su clase

4.3. Ajuste del procesamiento en función de las características de cada imagen




Figura 4.45: Resultado de aplicar *E2* para determinar el estado de crecimiento

de pertenencia en la tabla. Si por el contrario se introduce como nueva consulta una imagen nueva y no conocida hasta el momento, se calcula su clase de pertenencia y se almacena el resultado en la tabla independientemente de que luego se almacene también como caso o no. De esta forma, se ganará notablemente en eficiencia, ya que sólo se calcula la clase de pertenencia de cada imagen una vez.

4.3.3. Estructura de los casos y de la base de casos

Los casos contienen, además de la imagen en sí, la información usada para la indexación (clase de pertenencia o caracterización según los atributos anteriores), y la solución al procesamiento asociada a la imagen (métodos a usar en cada etapa y valor de los parámetros). La base de casos se organiza en dos tablas distintas, la que contiene las clases de pertenencia de todas las imágenes (tabla *Indices*), y la que contiene la información de los casos (tabla *Casos*), en otras palabras:

Indices(*IDImagen*, *Iluminacion*, *ErrorSembrado*, *ECrecimiento*, *Infestado*)
Casos(*IDImagen*, *MetodoS*, *MetodoE*, *MetodoF*, *ParS*, *ParS*, *ParS*)




Figura 4.46: Cálculo de la existencia de errores de sembrado en imágenes de estado de crecimiento medio (umbral = 14 %)

Durante el procesamiento de un nuevo caso se accede a ambas tablas por separado: primero se consulta la clase de pertenencia en la tabla *Indices* (etapas de indexación y recuperación), y posteriormente se accede a la solución al procesamiento, almacenada en la tabla *Casos* (etapas de reutilización y aprendizaje).


Inicialmente, la base de casos se generó con 4 casos por cada clase de indexación, dando lugar a una base de casos inicial de 56 casos. El número inicial de casos se validó en varias pruebas del sistema, durante las cuales se comprobó que al aumentar el número de casos iniciales los resultados no mejoraban y además la eficiencia del sistema (tiempos de cómputo) se veía repercutida negativamente.

Los casos fueron etiquetados a mano por expertos, usando la plataforma de procesamiento de imágenes desarrollada, a la que se incorporó el sistema CBR. Cada caso fue seleccionado procurando que los 4 casos asociados a cada clase presentaran imágenes lo más dispares posibles, para una mayor representación. Además, gracias a las facilidades brindadas por la plataforma de procesamiento de imágenes desarrollada, se comprobó en todo momento que las soluciones propuestas para los casos almacenados suministraban valores de cobertura altamente correlacionados con los valores de biomasa asociada a la imagen del caso.

4.3. Ajuste del procesamiento en función de las características de cada imagen



(a) imagen presentando una clara zona infestada



(b) proporción de cubierta vegetal = 87 %

Figura 4.47: Determinación de la existencia de una zona infestada, según si la proporción de píxeles de vegetación presentes después de la etapa de segmentación supera el 80 %

4.3.4. Recuperación

Una vez indexado el caso nuevo, el sistema debe decidir qué caso recuperar, de entre los que pertenecen a su misma clase. En esta etapa, es imprescindible ser capaces de recuperar siempre el caso más similar al caso nuevo. El método de cálculo de similitud entre casos juega aquí un papel fundamental. En la literatura pueden encontrarse infinidad de propuestas para tratar con casos que representan objetos o atributos (Bonissone y Ayub, 1993; Liao et al., 1998), pero en este caso lo que se tiene que comparar son las imágenes. Concretamente, se recuperará el caso previo cuya imagen sea la más similar a la imagen de entrada o caso nuevo.

Por tanto, la pieza clave una vez realizada la indexación es contar con una buena función de similitud entre imágenes. A la hora de comparar dos imágenes son muchas las características de éstas que se pueden tener en cuenta, (distancia entre píxeles, diferencias en intensidades, entornos de vecindad, etc.) y dependiendo del propósito que tenga el procesamiento sobre la imagen, las características a resaltar serán distintas.

Los métodos de cálculo de similitud utilizados en otros trabajos de CBR aplicado a procesamiento de imágenes (Perner, 1999, 2006), que comparan las imágenes mediante diferencias en los histogramas, diferencias en los valores medios, en la varianza o los

centroides, resultan demasiado sencillos para el problema planteado, donde las imágenes presentan un elevado número de características distintas, además de gran variabilidad.

En (Kato et al., 1999; Wang, 2003), se proponen dos métodos distintos para la clasificación e indexación de imágenes con muy buenos resultados, aunque debido a que se comparan exclusivamente aspectos locales de regiones de interés de la imagen y a su alto coste computacional, no pueden ser aplicados al problema planteado.

De entre los métodos de cálculo de similitud más generales cabe destacar el Structural SIMilarity (SSIM) Index (Wang et al., 2004), que hasta la fecha ha obtenido los mejores resultados sobre la base de datos **LIVE**². Sin embargo, al probarse sobre imágenes pertenecientes a la misma clase, en muchos casos devuelve valores idénticos para todas ellas debido al alto parecido que presentan, y por lo tanto no resulta útil para el cálculo de similitud en el problema planteado.

Por último, se llevó a cabo un análisis de los métodos de similitud entre imágenes clásicos resumidos en Di Gesù y Starovoitov (1999); Van der Weken et al. (2004). De entre ellos, se seleccionaron aquellos que daban mejor resultados para el tipo de imágenes a comparar. Los algoritmos de cálculo de similitud que se han probado son los siguientes: 1) *Global Distance (GD)*, que tiene en cuenta tanto las diferencias en el valor de intensidad de cada píxel, como la distancia de su posición en la imagen, esto último siendo importante y a tener en cuenta ya que es imposible asegurar que el trípode se coloca exactamente en el mismo sitio al tomar todas las fotos; 2) S_2 , que tiene en cuenta sólo la diferencia en el valor de intensidad de cada píxel, aunque esta vez en lugar de simplemente restar ambos valores, se basa en la distancia de Kullback-Leibler³; 3) *Mean Squared Error (MSE)*, el método clásico de cálculo de error cuadrático medio.

Las expresiones 4.10, 4.11 y 4.12 muestran el cálculo de similitud para cada uno de los métodos, dadas dos imágenes a comparar A y B de $M \times N$ píxeles cada una. La complejidad de los métodos es del orden de $\Theta(\text{Alto}^2 * \text{Ancho}^2)$ para GD y de $\Theta(\text{Alto} * \text{Ancho})$ para S_2 y $MSEA$.

²La base de datos de imágenes LIVE (2009), gestionada por la Universidad de Texas, está formada por un conjunto muy diverso de 648 imágenes, donde cada imagen se repite varias veces, añadiendo ruido aleatorio o degradando su calidad, con el fin de obtener una buena base de prueba para evaluar métodos de cálculo de similitud de imágenes

³suma de divergencias frente a coincidencias (Kullback y Leibler, 1951).

4.3. Ajuste del procesamiento en función de las características de cada imagen

$$GD(A, B) = \frac{2}{MN * (MN - 1)} \sum_{\forall A(i,j) \in A} \sum_{\forall B(l,m) \in B} \delta(A(i, j), B(l, m)),$$

donde, (4.10)

$$\delta(A(i, j), B(l, m)) = \alpha * (|i - l| + |j - m|) + \beta * GR(A(i, j), B(l, m)),$$

siendo,

$$GR(A(i, j), B(l, m)) = \frac{|A(i, j) - B(l, m)|}{\max(A(i, j), B(l, m))}$$

α y β se usan para dar más importancia a la distancia o al valor entre píxeles. Para el problema propuesto se ha tomado $\alpha = \beta = 0,5$, por lo que ambos criterios tienen asignado el mismo peso.

$$S_2(A, B) = \frac{\sum_{i=1}^M \sum_{j=1}^N |A(i, j) - B(i, j)|}{\sum_{i=1}^M \sum_{j=1}^N (A(i, j) + B(i, j))} \quad (4.11)$$

$$MSE(A, B) = \frac{1}{MN} \sqrt{\sum_{i=1}^M \sum_{j=1}^N |A(i, j) - B(i, j)|^2} \quad (4.12)$$

4.3.5. Adaptación

Para cada caso nuevo se usan los mismos métodos y valor de los parámetros que los usados en el caso recuperado. Como ya se ha comentado antes, la reutilización de la misma solución para un caso nuevo está justificada en casos como éste, donde el nuevo caso y el caso recuperado son muy similares.

Para poder cambiar la solución del caso recuperado el sistema debería tener conocimiento del dominio, para determinar los efectos de aumentar el valor de un parámetro en determinadas condiciones, o para ser capaz de determinar cuándo las diferencias entre

las imágenes indican una degradación en la solución que aconseja cambiar de método. Más aún, este conocimiento del dominio tiene una alta componente de intuición, muy difícil de codificar e incluir en el razonamiento.

En la literatura pueden encontrarse varias aproximaciones a métodos de adaptación que hacen frente a situaciones similares (López de Mántaras et al., 2005). Entre ellas cabe destacar por ejemplo el uso de ajustes evolutivos sobre el nuevo caso partiendo de la solución recuperada, de forma similar al ajuste realizado en la sección anterior (Gómez de Silva Garza y Maher, 2000). Sin embargo, se ha preferido inicialmente no incorporar dichos métodos por razones de eficiencia, ya que ralentizarían notablemente al sistema, impactando negativamente sobre el uso de la plataforma. Esta última es una cuestión que puede quedar abierta para trabajos futuros.

4.3.6. Aprendizaje

La fase de aprendizaje del sistema CBR decide si la consulta procesada debe incluirse en la base de casos o no. Actualmente, el sistema almacena el caso resultado de la consulta sólo si los resultados obtenidos por el caso resuelto muestran valores de cobertura de malas hierbas correlacionados con los valores de biomasa al menos en un 90 % y si el valor de cálculo de similitud entre la imagen del caso nuevo y aquella del caso recuperado es inferior al 95 %. De este modo, sólo se almacenan los casos cuya solución representa un buen procesamiento y cuya imagen no sea prácticamente idéntica a alguna ya existente, situación en la cual el caso nuevo no aportaría información diferente relevante. El método de aprendizaje propuesto parte de disponer de un valor alternativo para la zona muestreada como es la biomasa. Cuando no se dispone de un valor asociado de biomasa este método no es aplicable por lo que esta cuestión queda abierta para trabajos futuros.

4.3.7. Resultados

El sistema ha sido probado sobre un conjunto de 182 imágenes, pertenecientes tanto a campos de cereal de invierno como de maíz. Para ayudar a comprender mejor la aportación del CBR sobre la plataforma de procesamiento de imágenes, se han probado distintas configuraciones del sistema por separado. La tabla 4.8 describe todas las con-

4.3. Ajuste del procesamiento en función de las características de cada imagen

figuraciones evaluadas. Primero, se ha verificado el funcionamiento del sistema para las 182 imágenes sin CBR, usando las dos combinaciones de métodos que obtuvieron mejor resultado con ajuste genético. La primera configuración, **SinCBR1** usa la combinación S1-E3-F3, y la segunda, **SinCBR2**, usa la combinación S1-E2-F2.

Además se ha evaluado una configuración híbrida, **PseudoCBR**, que procesa todos los casos pertenecientes a la misma clase siempre del mismo modo, siguiendo unas pautas prefijadas, mostradas en la tabla 4.9. Así, la iluminación determinará qué segmentación debe ser usada, mientras que los métodos a utilizar en las etapas de eliminación y filtrado vendrán establecidos por el estado de crecimiento del cultivo, a no ser que haya errores en el sembrado o infestación, en cuyo caso los métodos seleccionados serán otros. Esta configuración ha sido incluida en las evaluaciones con el propósito de comprobar las diferencias de resultados entre ajustar cada imagen por separado (CBR completo) y ajustar las imágenes dependiendo sólo de sus características, y ver si el uso de un sistema CBR completo, mucho más costoso desde un punto de vista de cómputo, queda justificado.

Por último, se han evaluado tres variantes del CBR completo (**CBR1**, **CBR2** y **CBR3**), una por cada una de las funciones de cálculo de similitud entre imágenes descritas anteriormente. Para los tres CBRs la base de datos inicial estaba formada por cuatro casos por clase, es decir, un total de 56 casos ($4 * 14$).

Sistema	Descripción
SinCBR1	$S1(-0,7, 0,588, 0,136, 247); E3(30, 40, 0,9); F3(0,15)$
SinCBR2	$S1(-1, 2, 1, 224); E2(35, 5); F2(0,15)$
PseudoCBR	Indexación + pautas (véase tabla 4.9)
CBR1	CBR usando el método de cálculo de similitud GD
CBR2	CBR usando el método de cálculo de similitud S_2
CBR3	CBR usando el método de cálculo de similitud MSE

Tabla 4.8: Descripción de las distintas configuraciones del sistema evaluadas

Al igual que se hizo en el ajuste mediante genéticos, se ha estimado tanto la aproximación de los resultados al valor de la biomasa (correlación estadística), como el tiempo de respuesta (eficiencia), ya que interesa que el sistema pueda utilizarse en un futuro en tiempo real. Los resultados también se han comparado con la evaluación realizada

Atributo	Valor	Pautas a seguir
Iluminación	Sol	$S1(-1, 2, -1, 230)$
	Nubes	$S1(-0,7, 0,588, 0,136, 245)$
Estado de crecimiento	Bajo	$E2(35, 5); F3(0,10)$
	Medio	$E3(30, 40, 0,7); F2(0,3)$
	Alto	$E3(10, 20, 0,9); F3(0,5)$
Error en el sembrado	Sí	$E1(0,75)$
Infestación	Sí	$E3(2, 5, 0,99); F3(0,65)$

Tabla 4.9: Pautas seguidas por **Pseudo-CBR**

por expertos humanos, que tal como se explicó en el capítulo 2 tiende a ser subjetiva. Todos los resultados se muestran en la tabla 4.10.

Sistema	Correlación	Tiempo medio empleado por imagen (sec)
SinCBR1	0.615	1.21
SinCBR2	0.587	0.5
Pseudo-CBR	0.684	1.37
CBR1	0.822	2.10
CBR2	0.799	1.63
CBR3	0.797	1.62
Expertos	0.578	-
Media SinCBR	0.601	0.85
Media CBR	0.806	1.78

Tabla 4.10: Resultados del estudio comparativo de la plataforma con y sin CBR

Los sistemas sin CBR alcanzan correlaciones medias con la biomasa en torno al 60 % (58 % **SinCBR2** y 61 % **SinCBR1**). Es importante recordar que el ajuste genético se realizó sobre imágenes de cereal, mientras que en este estudio se utiliza un conjunto formado por imágenes de dos tipos de cultivo, cereal y maíz. El presente trabajo es novedoso pues son pocos los casos en los que se aborda la detección de infestación en dos tipos de cultivo simultáneamente. Una vez más, la combinación S1-E3-F3 (**SinCBR1**)

4.3. Ajuste del procesamiento en función de las características de cada imagen

es mejor que S1-E2-F2 (**SinCBR2**) y a la vez es más lenta.

Modificar el procesamiento sobre cada imagen dependiendo de las características que ésta presenta (**PseudoCBR**), mejora los resultados de los sistemas sin CBR casi un 10 % (68,4 % de correlación media), lo que vuelve a corroborar lo determinantes que son los atributos de caracterización (Iluminación, Estado de crecimiento, Errores en el sembrado, Infestación) para la obtención de una estimación precisa de la cobertura, como ya se discutía en la tabla 4.6.

El uso de un CBR completo, mejora el ajuste otro 10 % más (80,6 % de media), demostrando de este modo que no sólo es importante procesar las imágenes dependiendo de a qué clase pertenecen, sino que también es necesario ajustar cada imagen por separado. Esto significa, además, que el CBR ha mejorado los resultados de la plataforma desarrollada (y partiendo de valores ajustados previamente mediante genéticos sólo para un tipo de cultivo, cereal) en un 20 % (correlación media sin CBR = 60,1 %, media con CBR 80,6 %). Estos resultados son muy buenos, máxime si se tiene en cuenta que las imágenes utilizadas pertenecen a dos tipos de cultivo distinto (cereal y maíz) y provienen de muestreos realizados a lo largo de seis años.

Las diferencias entre las distintas configuraciones del CBR son mínimas, alcanzando **CBR1** una correlación de 82,2 % frente a un 79,9 % del **CBR2** y al 79,7 % del **CBR3**. Esto demuestra que los tres métodos de similitud funcionan de forma análoga, siendo *GD* el de mejores resultados, aunque también es el más lento computacionalmente hablando.

Obviamente, los sistemas CBR, debido a todo el proceso de clasificación, razonamiento y aprendizaje que efectúan son más lentos, (1s más por imagen) que el procesamiento de imágenes sin CBR. Sin embargo, a la hora de construir mapas de tratamiento, cuando por tanto el tiempo real no es importante, mejorar los resultados en un 20 % es altamente preferible a ganar 1s por imagen en su elaboración.

En cuanto a la valoración de los expertos, se puede comprobar cómo las valoraciones sobre las imágenes son peores que las efectuadas incluso por los sistemas básicos sin CBR, lo que corrobora la hipótesis de subjetividad.

Finalmente, la bondad del sistema completo de procesamiento de imágenes incluyendo el CBR puede comprobarse visualmente al comparar los mapas de cobertura de

malas hierbas construidos a partir de los valores de cobertura devueltos y la biomasa. La figura 4.48 muestra dicha comparación para los mapas creados por interpolación a partir de un muestreo de 180 puntos llevado a cabo el año 2005 en un campo de cereal de 160m de largo por 80m de ancho. Los valores de cobertura devueltos por la plataforma muestran una correlación con la biomasa del 82 %.




Figura 4.48: Comparación de los mapas de cobertura de malas hierbas obtenidos recogiendo biomasa (datos reales) y estimando los valores de cobertura usando la plataforma de imágenes (correlación del 82 %)

Capítulo 5

Detección de malas hierbas en tiempo real

El tiempo es una imagen móvil de la eternidad

Platón

El objetivo principal en lo relativo al procesamiento en tiempo real es el diseño y desarrollo de métodos de Visión Artificial que permitan estimar la cobertura de malas hierbas, cultivo y suelo en una secuencia de imágenes (vídeo), tomadas directamente desde el tractor a la vez que éste se desplaza sobre el campo. Al igual que los métodos sobre imágenes estáticas, éstos deben ser capaces de procesar de forma completamente automática cada imagen, suministrando una estimación precisa.

Las principales diferencias de este caso respecto al procesamiento de imágenes estáticas, son el procedimiento de adquisición de las imágenes y el tiempo disponible para el procesamiento de las mismas, que es muy limitado.

Las velocidades de tratamiento habituales se sitúan en torno a los $7Km/h$, equivalentes a casi $2m/s$. La velocidad de grabación de las cámaras de vídeo convencionales

suele ser de 25 *frames*¹ *por segundo (fps)*, lo cual implica que entre cada frame (a la velocidad de 2m/s) el tractor habrá avanzado 8cm. Por tanto, para ser capaces de realizar un muestreo continuo de malas hierbas con precisión centimétrica, es necesario procesar todos los frames según vienen, o lo que es lo mismo, procesar una imagen cada 0,04s. Esta restricción temporal sobre el tiempo de respuesta del sistema se debe tener en cuenta al desarrollar un sistema de detección de malas hierbas y en este sentido es en el que se utilizará el término *tiempo real* en la presente memoria.

En lo que sigue se describen los trabajos llevados a cabo para discriminar en tiempo real mediante técnicas de VA malas hierbas en dos tipos de cultivo muy distintos: maíz y caña de azúcar. Todos los métodos desarrollados en este capítulo han sido programados en C++ usando el entorno de programación Visual Studio, y compilados en filtros DirectShow, para su uso directo en sistemas operativos Windows a partir de aplicaciones ya incluidas, como por ejemplo GraphEdit.

5.1. Detección de malas hierbas en tiempo real en maíz

En el caso del maíz las malas hierbas más frecuentes y objeto de este estudio son *Sorghum*, *Cyperus*, *Xanthium* y *Datura*. Como ya se vio en el Capítulo 4, algunas de estas infestaciones se caracterizan por ser difícilmente distinguibles del cultivo, tanto en forma como en lo que respecta a su signature espectral o color en el momento en el que deben ser aplicados los tratamientos, por lo que lo más conveniente es utilizar la posición como criterio de discriminación, en otras palabras considerar como infestación todo aquello que crece fuera de las líneas de cultivo, que en el caso del maíz presentan una separación aproximada de 70cm. Por tanto, una vez más, el problema consiste en localizar, y separar del resto de la imagen las líneas de cultivo y contabilizar como mala hierba toda la cubierta vegetal que queda entre líneas. Es importante que las líneas de cultivo se detecten con precisión para estimar la densidad del cultivo, ya que como se explicó anteriormente, este parámetro es también importante a la hora de decidir la cantidad de tratamiento a aplicar, debido a que el grado de amenaza de una infestación depende del nivel de desarrollo del cultivo, que incide en la capacidad que tiene éste de competir con la mala hierba

¹frames: imágenes que en secuencia forman el vídeo

5.1. Detección de malas hierbas en tiempo real en maíz

Aún tratándose de la misma problemática, el procesamiento será muy distinto al visto en el Capítulo 4, debido a las diferencias en el modo en que se toman las imágenes y a las limitaciones en tiempo de respuesta, como se detalla a continuación.

5.1.1. Adquisición de imágenes

El objetivo final del sistema de percepción en tiempo real es, además de efectuar el muestreo continuo de malas hierbas, usar su salida como entrada a un controlador sobre la barra de tratamientos que aplique herbicida directamente, en función de las coberturas de infestación y cultivo estimadas, que se verá en el Capítulo 6. Este objetivo, permitiría llevar a cabo el tratamiento selectivo de malas hierbas de forma totalmente automatizada y en tiempo real.

La barra de tratamientos de herbicida usada tiene diez metros de ancho, distribuidos a lo largo de cinco secciones independientes de dos metros cada una. Para que la salida del sistema de percepción pueda ser usada como entrada útil al controlador de la barra de tratamientos, el sistema deberá ser capaz de estimar la mala hierba y el cultivo presente sobre todo el ancho de la barra, es decir, sobre los diez metros.

Para capturar información de diez metros de campo con una cámara convencional montada sobre el tractor, ésta se coloca sobre el techo del tractor, a 2,15m de altura y con un ángulo cuya inclinación máxima con respecto al plano horizontal es de 10 grados, figura 5.1, lo que permite explorar la situación del campo aproximadamente 8 metros por delante. Al no colocar la cámara perpendicular al suelo, se produce una proyección de perspectiva del sistema óptico tal que se pierde la posibilidad de que las líneas de cultivo aparezcan en la imagen como columnas verticales, que tanto ayudaba al procesamiento propuesto en el capítulo anterior para las imágenes de los muestreos. Pero para obtener imágenes del mismo estilo, capturando 10 metros de ancho con una única cámara, sería necesario colocar ésta en un mástil a una altura de diecisiete metros, algo inviable.

La figura 5.2 muestra la perspectiva producida por la colocación casi horizontal de la cámara. Las líneas de cultivo, paralelas al campo de visión en la escena, se proyectan sobre el plano de la imagen como rectas con un mismo punto de intersección en el horizonte, llamado también punto de fuga. La perspectiva en las líneas de cultivo se



Figura 5.1: Método de toma de las imágenes para la detección de infestación en tiempo real en maíz. La cámara se coloca directamente sobre el tractor, a 2,15m de altura y con un ángulo de 10 grados de inclinación sobre la horizontal

produce porque el detalle de la parte baja de la imagen es mucho mayor que el de la parte alta, dado que la zona de la escena proyectada sobre ésta se encuentra más cerca de la cámara. Así, el espacio entre líneas de cultivo (constante en el campo), varía en la imagen, reduciéndose de abajo hacia arriba, a consecuencia de la pérdida de detalle. Por otro lado, esta colocación de la cámara, junto con el movimiento del tractor, hace que en frames consecutivos se muestren las mismas zonas del campo repetidas, primero en la parte alta de la imagen y luego en la parte baja (primero desde lejos y luego desde más cerca a medida que el tractor avanza). Siempre a consecuencia de la perspectiva, el movimiento se plasma sobre frames consecutivos con desplazamientos hacia abajo y hacia los lados, que además aumentan en magnitud a medida que se acercan a la parte baja de la imagen, figura 5.2.

Las imágenes resultantes muestran una perspectiva del campo parecida a la que se ve desde la cabina del tractor, figura 5.3. En lugar de ver sólo dos líneas de cultivo, ahora en cada imagen se muestran entre 5 y 7 líneas de cultivo (dependiendo de los desplazamientos en la orientación del tractor) en la parte baja de la imagen, y muchas más en la parte alta de la imagen.




Figura 5.2: Perspectiva resultante en las imágenes debido a la colocación de la cámara con un ángulo de 10 grados sobre la horizontal

Con esta configuración, los vídeos sólo abarcan 6,5m de ancho, en lugar de los 10m necesarios. Sin embargo, no es posible colocar la cámara en una posición más elevada, debido a que la precisión obtenida en las imágenes sería demasiado pequeña (10 m comprimidos en tan sólo 520 píxeles). Debido a esto, las únicas soluciones son o bien no utilizar la primera y última sección de la barra de tratamiento (mantenerlas siempre cerradas), trabajando sólo sobre los 6m correspondientes a las 3 secciones centrales, o bien instalar otra cámara al otro lado del techo de la cabina del tractor y efectuar posteriormente una fusión de la información recogida por ambas cámaras. Sea cual sea la configuración final adoptada, en ambos casos el procesamiento se llevaría a cabo a partir de vídeos adquiridos con la configuración actual, por lo que la aproximación propuesta en esta sección para tratar la imagen de 6,5m será la base de la adquisición de la franja total de 10m para el caso de la detección de mala hierba y el posterior tratamiento.

Todos los vídeos han sido, una vez más, tomados a lo largo de varios años en distintos campos, disponiendo actualmente de más de 12h de material, asegurando que se cuenta con una gran variedad de situaciones, tanto de iluminación (días soleados o nublados) y textura del suelo (suelo seco o húmedo), como de estado de crecimiento del cultivo o de cantidad y posición de malas hierbas, tal como se muestra en la figura 5.3.

A todos los problemas asociados a distintas condiciones de la vegetación (errores de sembrado, infestación, distintos estados de crecimiento, etc.) a los que debe hacer frente el procesamiento, hay que añadir los problemas derivados de la inestabilidad causada por el movimiento del tractor y la irregularidad del terreno, que produce imágenes borrosas, con ruido, e incluso desplazamientos de la orientación de la cámara (véase figura 5.3(b)).

Todos los vídeos fueron tomados con cámaras convencionales Sony DCR PC110E y JVC GR-DV700E, fáciles de conseguir, baratas y de calidad suficiente para obtener imágenes nítidas (720x576 píxeles). La idea es utilizar equipos estándares que permitan desarrollos baratos de fácil instalación que no supongan un incremento significativo sobre el precio de un tractor convencional. Las dos cámaras utilizadas disponen de conexión i.Link o IEEE1394 que permite la adquisición de 25 frames por segundo desde la cámara sin necesidad de disponer de una etapa de digitalización.

5.1. Detección de malas hierbas en tiempo real en maíz




Figura 5.3: Ejemplo de frames

5.1.2. Procesamiento propuesto

Como en el caso de las imágenes estáticas, el procesamiento debe ser capaz de determinar los porcentajes de mala hierba, cultivo y suelo presentes en cada frame capturado por la cámara de vídeo, para calcular el riesgo que supone para el cultivo la mala hierba detectada (Ribeiro et al., 2005).

Al igual que en el caso estático, el procesamiento consta de 3 etapas: 1) Segmentación de la capa de vegetación frente al resto, 2) Detección y eliminación de las líneas de cultivo y 3) Detección de las malas hierbas como la cobertura vegetal que crece entre líneas de cultivo.

Para llevar a cabo un procesamiento en tiempo real a $25fps$, es necesario procesar un frame cada $0,04s$. Para alcanzar estos tiempos de respuesta, el procesamiento propuesto se divide en dos partes. La primera realiza todas las operaciones consideradas necesarias para extraer correctamente las líneas de cultivo en todas las situaciones, independientemente del tiempo requerido. Los resultados de esta primera parte se usan como entrada a la segunda parte, que adapta dichos resultados al frame actual en un tiempo por debajo de los $0,04s$, logrando de este modo la detección de la infestación en tiempo real.

La primera parte se considera un procesamiento a prueba de fallos, que funciona siempre, bajo todos los tipos de situaciones que pueden encontrarse en el campo y para las cuales no sería suficiente un procesamiento rápido, incapaz de tratar adecuadamente cambios drásticos de iluminación, distintos estados de crecimiento de la vegetación, errores de sembrado y todos los problemas asociados con el traqueteo del tractor y la irregularidad del terreno (desplazamientos, imágenes borrosas, ruido). A esta primera parte del procesamiento se le ha llamado Procesamiento a Prueba de Fallos (**PPF**). La segunda parte recibe el nombre de Procesamiento a Tiempo (**PT**).

La figura 5.4 muestra el diagrama de flujo del procesamiento propuesto. Cada vez que un nuevo frame es capturado por la cámara, el primer paso (común para **PPF** y **PT**) consiste en segmentar la cubierta vegetal del resto. Posteriormente, se transfiere simultáneamente la imagen segmentada a ambas partes del procesamiento.

Debido a que **PPF** no trabaja en tiempo real, es probable que al llegar el nuevo

5.1. Detección de malas hierbas en tiempo real en maíz

frame **PPF** no esté aún listo para procesarlo (se encuentre aún procesando información anterior), por lo que el frame se almacena en un registro. Cuando **PPF** está listo para analizar una nueva imagen, recoge todos los frames almacenados en espera de ser procesados, y los usa todos en el procesamiento, almacenando finalmente el resultado en el registro *Imagen de Referencia*. Además, **PPF** actualiza también el valor de umbral usado en la segmentación, a partir de un ajuste sobre el último frame capturado, para que la segmentación se adapte rápidamente a los cambios de iluminación. Al mismo tiempo e independientemente de **PPF**, **PT** procesa cada nuevo frame según llega, usando como guía la última *Imagen de Referencia* creada por **PPF**. A continuación se describe detalladamente cada paso.

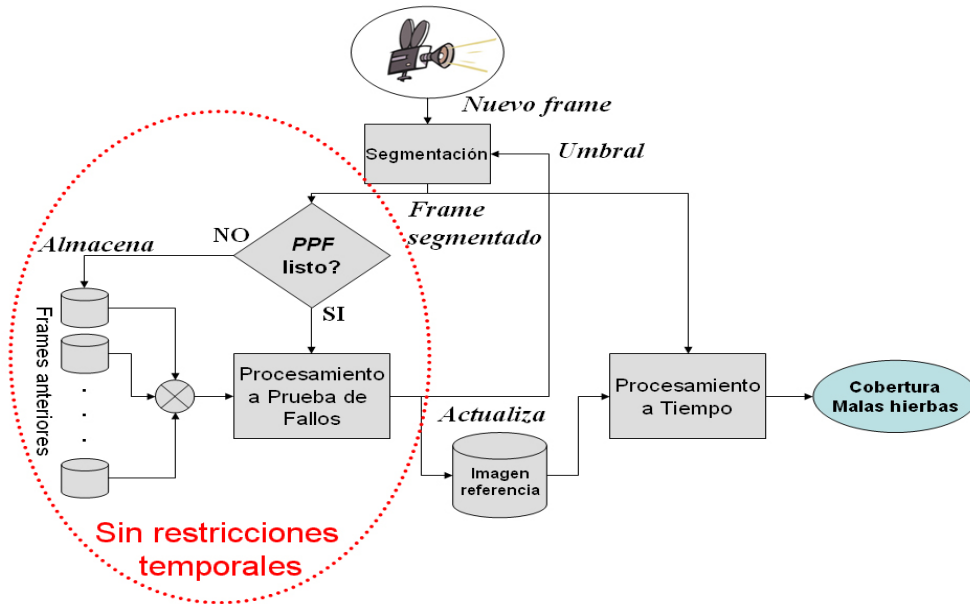


Figura 5.4: Procesamiento propuesto para tiempo real

Segmentación

El método de segmentación utilizado no es más que **S1**, explicado en el Capítulo 4 y que demostró dar muy buenos resultados sobre todo tipo de imágenes. Los valores de las constantes de la combinación lineal se se fijan a los obtenidos con el ajuste

mediante algoritmos genéticos del capítulo anterior ($r = -0,884, g = 1,262, b = -0,311$) y variando el valor del umbral según la imagen.

La variación del umbral es crucial para un procesamiento robusto ante cambios de iluminación, que ocurren con frecuencia incluso durante un mismo recorrido del campo debido a condiciones meteorológicas cambiantes (especialmente en días con nubes y claros).

PPF ajusta automáticamente el umbral cada vez que lleva a cabo el procesamiento de un nuevo frame, usando para ello el último frame capturado por la cámara. Los métodos explorados para la umbralización de la imagen en escala de grises que resulta de la combinación lineal de los planos RGB son dos. El primero es el conocido método de umbralización por máxima varianza en el histograma (Otsu, 1979) muy usado en procesamiento de imágenes, mientras que el segundo consiste en tomar como valor de umbral el valor de intensidad medio de todos los píxeles, ecuación 5.1. Esta segunda aproximación más sencilla de calcular devuelve valores de umbral muy próximos a los obtenidos mediante el ajuste con algoritmos genéticos.

$$Umbral = \frac{\sum_{x=1}^N \sum_{y=1}^M (-0,884 * R(x, y) + 1,262 * G(x, y) - 0,311 * B(x, y))}{M * N} \quad (5.1)$$

La figura 5.5 muestra el resultado de ambas aproximaciones sobre dos frames de entrada distintos. El método de Otsu tiene tendencia a ajustar la umbralización usando valores de umbral más altos que el método de media de intensidades (220 y 231 frente a 203 y 215 respectivamente), incluyendo de este modo más píxeles en la cubierta vegetal. Esto tiene como inconveniente que las líneas de cultivo y malas hierbas están completamente pegadas, dificultando muchísimo el procesamiento. Dado que este efecto no aparece en la media de intensidades, se ha optado por usar este método.

La figura 5.6 muestra los claros beneficios de la técnica de ajuste del umbral frente a la segmentación con umbral fijo.

Una vez segmentado el frame, se elimina el tercio superior de la imagen, ya que muestra una zona demasiado alejada de la cámara en la que es imposible e innecesario

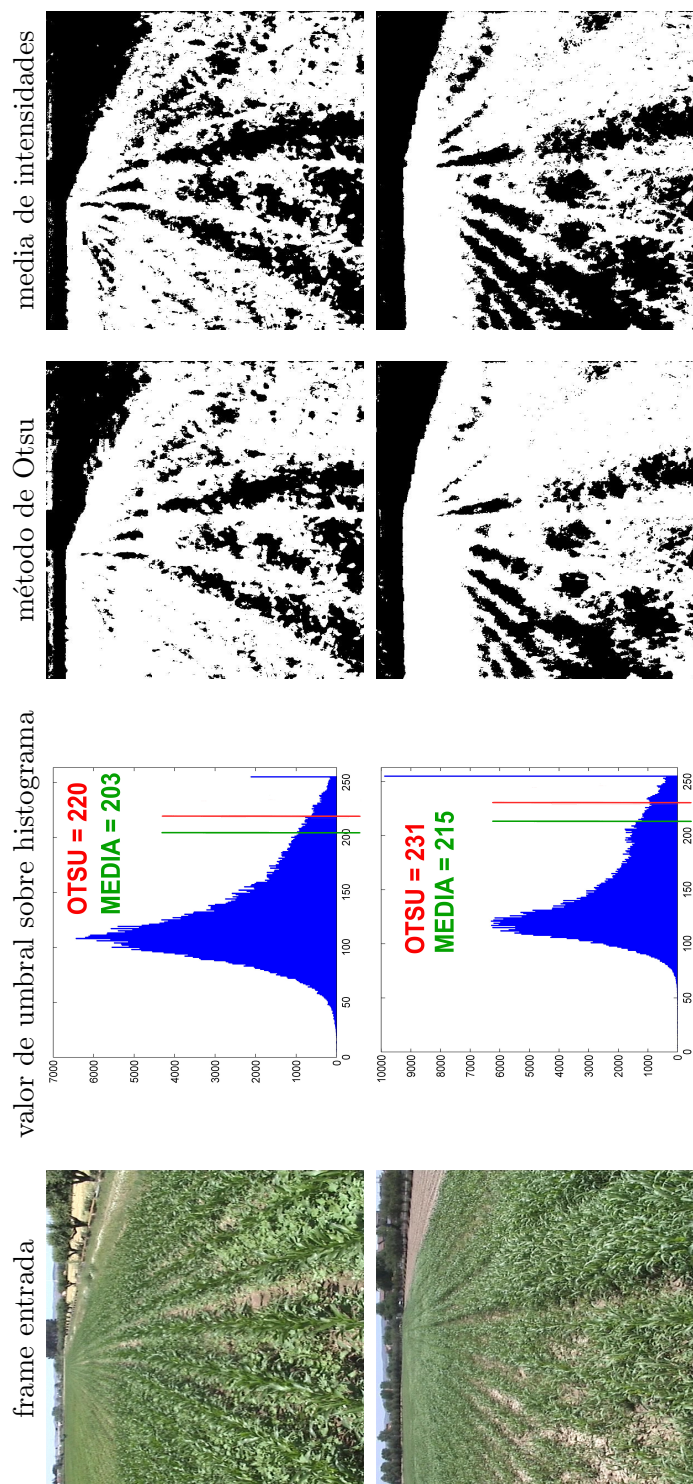


Figura 5.5: Comparación de los métodos de umbralización variable explorados (Otsu y media de intensidades) sobre dos frames ejemplo

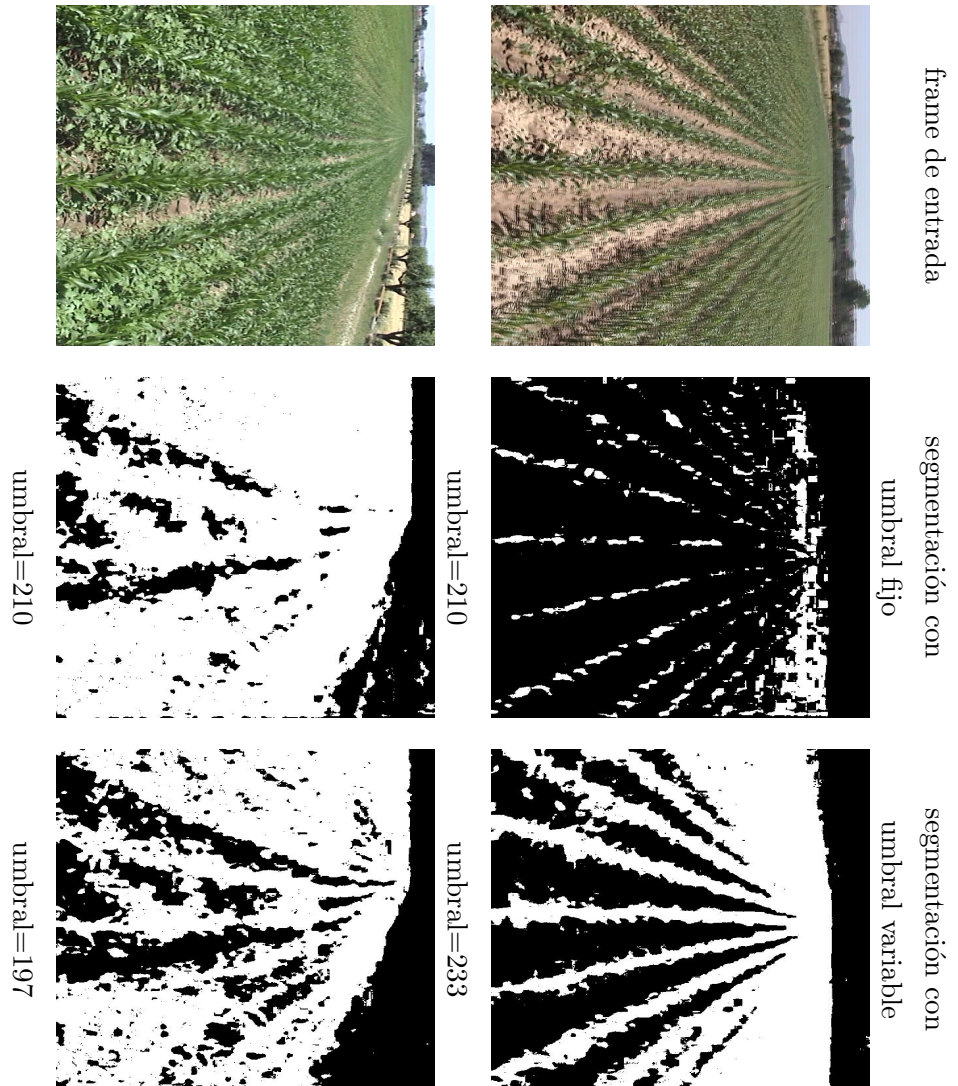


Figura 5.6: La variación del umbral durante el procesamiento adaptada a cada imagen logra una segmentación robusta a los cambios de iluminación producidos durante un mismo recorrido en el campo

5.1. Detección de malas hierbas en tiempo real en maíz

detectar la mala hierba. El resultado final de la segmentación sobre un frame se muestra en la figura 5.7.



Figura 5.7: Segmentación de un frame. El tercio superior se elimina por mostrar una zona demasiado alejada de la cámara. Al reducir la región de interés también se reduce el tiempo de procesamiento

Procesamiento a Prueba de Fallos (*PPF*)

El objetivo de *PPF* es la correcta detección de todos los píxeles pertenecientes a las líneas de cultivo bajo todas las situaciones posibles. El resultado es la creación de una imagen binaria donde sólo las líneas de cultivo tienen valor distinto de cero. Esta imagen se almacena en un registro y constituye la *Imagen de referencia* usada por *PT* como guía en el procesamiento. Esta imagen de referencia, como ya se ha dicho, es fundamental para que el procesamiento sea preciso y robusto ante todo tipo de situaciones y condiciones adversas.

Como se vio en el Capítulo 3, algunos trabajos aprovechan la perspectiva presente en la imagen para usar la transformada de Hough y extraer las líneas de cultivo (Hague et al., 2006; Tellaeche et al., 2008a,b). Sin embargo, la transformada de Hough es un proceso demasiado complejo y lento, difícil de usar en tiempo real, además de presentar problemas cuando hay errores de sembrado o aparecen rodales grandes de malas hierbas, es decir, infestaciones que lo cubren todo.

Por otro lado, en el guiado de vehículos agrícolas se ha utilizado la detección de líneas de cultivo en tiempo real en varios trabajos (Bakker et al., 2008; Billingsley y Schoenfisch, 1997; Gottschalk et al., 2008; Keihcer y Seufert, 2000; Leemans y Destain, 2006; Olsen, 1995; Reid et al., 2000; Tillet y Hague, 1999; Torii, 2000), sin embargo, en estos trabajos el objetivo es sólo aproximar las ecuaciones de las rectas que dirigen las líneas de cultivo para determinar la dirección del vehículo en cada instante. En este caso es necesario determinar todos los píxeles de la imagen que corresponden a cultivo, por lo que se necesitan métodos más precisos.

Dado que **PPF** no trabaja en tiempo real, varios frames nuevos se capturan mientras **PPF** está ocupado procesando información anterior. Cuando **PPF** está listo, todos estos frames (ya segmentados) se combinan mediante una operación *AND*. De este modo, en la imagen resultante sólo se mantendrán los píxeles de cubierta vegetal que han sido detectados como tal de modo persistente en todos los frames anteriores. En la figura 5.8(a) puede verse un ejemplo del resultado de la operación *AND* sobre la imagen de la figura 5.7(b) y los seis frames anteriores. Se puede observar que sólo permanecerán en blanco aquellos píxeles pertenecientes al centro de las líneas de cultivo, exceptuando algunos de mala hierba si el rodal encontrado es suficientemente grande (aparece en varios frames consecutivos).

Aún cuando el rodal de mala hierba es suficientemente grande como para “sobrevivir” a la operación *AND*, el número de píxeles de mala hierba restantes se habrá reducido en gran medida, quedando sólo aquellos pertenecientes al centro del rodal. Por lo tanto, para eliminarlos del todo bastará con efectuar una extracción de regiones y filtrar todas aquellas demasiado pequeñas ($area < 2000$ píxeles) para ser líneas de cultivo. El umbral de filtrado ha sido muy fácil de ajustar dado que las líneas de cultivo muestran tamaños de entre siete y diez veces superiores a las malas hierbas. Además, para evitar que malas hierbas “conectadas” al cultivo sean reconocidas como parte de la misma región que el cultivo, como ocurre en la figura 5.8(a), previamente a la extracción de regiones se realiza una apertura morfológica sobre la imagen.

La figura 5.8(b) muestra un ejemplo del resultado de la apertura morfológica sobre la figura 5.8(a), donde se puede ver claramente cómo las malas hierbas son “desconectadas” del cultivo. La figura 5.8(c) muestra el resultado del filtrado por tamaño de región. La figura 5.8d muestra los mismos resultados superpuestos sobre la imagen de

5.1. Detección de malas hierbas en tiempo real en maíz

entrada, donde se aprecia claramente cómo *PPF* extrae de modo preciso las líneas de cultivo.




Figura 5.8: Resultados de *PPF*. (a) operación *AND* sobre 6 frames consecutivos. (b) apertura morfológica para “desconectar” las malas hierbas del cultivo (c) las regiones pequeñas (*area* < 2000 píxeles) son eliminadas, dejando sólo las líneas de cultivo (d) imagen de referencia resultado sobre original (figura 5.7)

Procesamiento a Tiempo (*PT*)

En la segunda parte del procesamiento, *PT*, se tienen que analizar los frames en un tiempo determinado. El objetivo final es extraer los tres elementos de interés: suelo

(obtenido a partir de la segmentación), cultivo y malas hierbas. Nótese que en (**PPF**) sólo se detecta el cultivo.

En lugar de tratar la imagen como un todo, **PT** divide el frame en franjas horizontales. Para cada una de ellas, se crea un vector con tantos componentes como columnas tiene la imagen, y se rellena cada componente del vector con el número de píxeles de vegetación presentes en dicha columna para todas las filas contenidas en la franja, ecuación 5.2. Luego, cada vector se explora de izquierda a derecha buscando *varios* valores *altos* consecutivos, y marcándolos como parte del cultivo.

$$V(x) = \sum_{x=\text{inicio_franja}}^{\text{fin_franja}} F(x, y) \quad (5.2)$$

Se considera que un valor es *alto* si es mayor que 3/4 de la altura de la franja (número de filas que abarca). Valores altos consecutivos se consideran *varios* si superan un cierto umbral que se ajusta automáticamente al inicio, usando el mínimo número de columnas consecutivas detectadas como líneas de cultivo por **PPF** en la parte baja de la imagen (última fila). Es decir, este umbral se puede definir como el ancho esperado, en número de píxeles, de las líneas de cultivo en la parte baja de la imagen.

Debido al efecto de la perspectiva, las líneas de cultivo son más anchas en la parte baja de la imagen que en la parte alta, por lo que el umbral debe reducirse para cada segmento de forma proporcional. Esta reducción puede calcularse de antemano, conociendo los parámetros de la cámara y haciendo uso de cálculos básicos de transformación de perspectiva (Barnard, 1983). Los parámetros de la cámara tanto extrínsecos (rotaciones y traslaciones respecto a un sistema de referencia) como intrínsecos (distancia focal y distorsiones de la lente) se pueden obtener mediante un procedimiento de calibración con el paquete de Matlab CCTool (CIT, 2007).

El número de franjas en las que se divide la imagen influye sobre el resultado de **PT**. La figura 5.9 muestra el efecto de usar 10, 25 y 40 franjas sobre la imagen de la figura 5.7(b). Usar pocas franjas hace que el procesamiento sea muy rápido pero poco preciso, mientras que usar muchas franjas hace que el procesamiento mejore ostensiblemente a costa de aumentar el tiempo de cómputo empleado.

5.1. Detección de malas hierbas en tiempo real en maíz

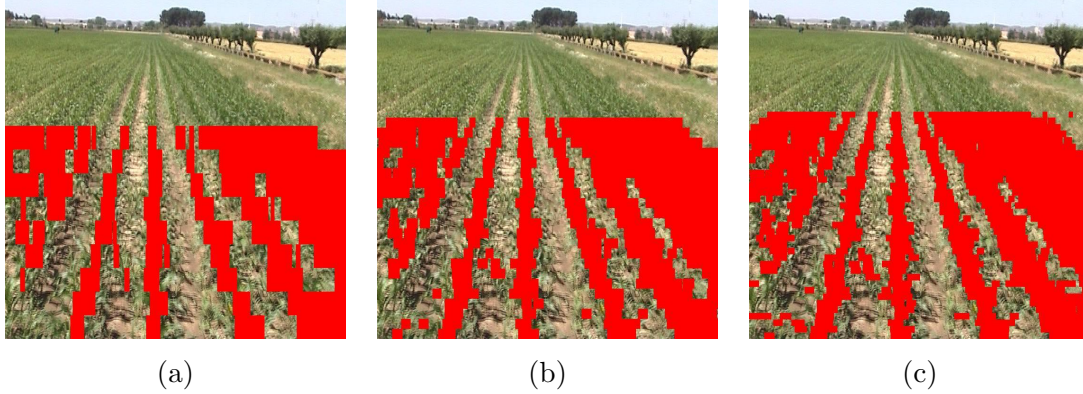


Figura 5.9: Comparación de resultados de **PT** con distinto número de franjas. (a) 10 franjas. (b) 25 franjas. (c) 40 franjas

El anterior proceso detecta correctamente las líneas de cultivo, pero incluye además la inmensa mayoría de las malas hierbas, más cuantas más franjas se usen, véase la diferencia entre la figura 5.9(a) y (c).

Para distinguir entre cultivo y malas hierbas, **PT** utiliza la imagen de referencia creada por **PPF**. La figura 5.10(a) muestra una superposición de los resultados de **PT** de 25 franjas y **PPF**. Es evidente que de entre todos los “bloques” extraídos por **PT** (en rojo) sólo pertenecen a cultivo aquellos que se solapan con algún píxel de cultivo en la imagen de referencia creada por **PPF**. La etapa de corrección, por lo tanto, será tan sencilla como desechar todos aquellos valores detectados como cultivo por **PT** y no por **PPF**, tal como se puede ver en la figura 5.10(b).

Finalmente, los píxeles de mala hierba serán todos aquellos pertenecientes a la cubierta vegetal que no hayan sido reconocidos como cultivo. El resultado final del procesamiento completo sobre la imagen de la figura 5.7(a) puede verse en la figura 5.11.

5.1.3. Resultados

La combinación de un procesamiento rápido (**PT**), que asegura resultados en tiempo real, junto con un procesamiento robusto ante cualquier situación (**PPF**), hacen




Figura 5.10: Resultados de *PT*. (a) comparación de los resultados de *PPF* (azul) y *PT* de 25 franjas (rojo). (b) corrección de los resultados de *PT* usando la imagen referencia creada por *PPF* (bloques descartados en azul claro)



Figura 5.11: Discriminación final entre cultivo (rojo) y malas hierbas (azul)

5.1. Detección de malas hierbas en tiempo real en maíz

que el procesamiento global alcance muy buenos resultados ante una gran variedad de situaciones.

La figura 5.12 muestra el resultado del procesamiento sobre cuatro frames en distintas situaciones. Las figuras 5.12(a) y (c) presentan los resultados sobre frames donde hay rodales de malas hierbas grandes y “conectados” a las líneas de cultivo, donde se ve cómo gracias a **PPF** éstos no se confunden con el cultivo.

En la figura 5.12(b) se muestra el resultado sobre un frame donde además de haber varios rodales de malas hierbas, también aparece un error de sembrado. En este caso, la parte de la línea de cultivo en la que se ha producido el error de sembrado se reconoce como mala hierba, lo cual es un error asumible, pues supondría la aplicación de herbicida en una zona de cultivo; pero con una estrategia conservadora, en caso de duda es mejor aplicar herbicida, ya que no aplicar tratamiento es arriesgarse a no eliminar correctamente todas las malas hierbas.

La figura 5.12(d), por último, muestra el resultado sobre un frame en el que, debido a un bache en el terreno, se ha producido un desplazamiento en la orientación de la cámara, haciendo aparecer más líneas de cultivo de lo normal. Como se puede observar, la aproximación propuesta se comporta de forma robusta realizando adecuadamente la discriminación.

Todo esto se debe, en parte, gracias a que el tiempo de procesamiento medio de (**PPF**) es de 0,3s, por lo que finalmente se efectúa el procesamiento cada 7 frames, alcanzando un buen equilibrio entre procesar suficientes frames, garantizando que el operador *AND* filtra el máximo número de malas hierbas, y no procesar demasiadas imágenes para mantener una elevada frecuencia de refresco de la imagen de referencia y con ello asegurar que el procesamiento se adapta rápidamente a situaciones cambiantes.

Otro punto fuerte del sistema desarrollado es que no necesita el ajuste de ningún parámetro de manera manual, ya que los pocos parámetros del algoritmo se calibran automáticamente a partir de los mismos frames (umbral de segmentación, ancho esperado de las líneas de cultivo), o de la óptica de la cámara (reducción del ancho de las líneas de cultivo en partes altas de la imagen debido a la perspectiva), mientras que todos los demás se pueden dejar fijos a los siguientes valores:




Figura 5.12: Resultados del sistema ante situaciones variables

- umbral de filtrado de regiones por tamaño en $PPF = 2000$
- número de franjas de $PT = 25$
- número mínimo de píxeles de vegetación por segmento en $PT = 3/4 * \text{altura franja}$

5.2. Detección de malas hierbas en tiempo real en caña de azúcar

Australia es el octavo mayor productor de caña de azúcar del mundo, produciendo más de 36 millones de toneladas anuales. Prácticamente toda la caña de azúcar se cultiva en la costa noreste, en la región de Queensland, en las zonas más cálidas de clima subtropical. Debido a su cercanía con el gran arrecife de coral, que se extiende precisamente en la misma zona, el gobierno australiano y en especial la región de Queensland han impuesto restricciones muy severas sobre el uso de fitosanitarios en el cultivo de azúcar. Se cree que dichos productos, transportados por el viento, están dañando muy seriamente al delicado ecosistema presente en el arrecife de coral, patrimonio de la humanidad según la Unesco y considerado como una de las siete maravillas naturales del mundo.

Más precisamente, las directivas actuales solicitan que se rebaje el uso de herbicidas en un 30 % de aquí a tres años, por lo que la industria azucarera está actualmente financiando grandes proyectos de investigación con el fin de desarrollar tecnología que permita disminuir la cantidad de agroquímicos utilizada sin perder eficacia en el tratamiento. Entre estos proyectos está el que se lleva a cabo en el *National Centre for Engineering in Agriculture (NCEA)* (NCEA, 2008). El objetivo final de este proyecto es el mismo que el visto para campos de maíz, es decir, realizar un sistema de aplicación selectiva de tratamientos en tiempo real basado en VA.

La caña de azúcar es un tipo de cultivo muy distinto al maíz, por lo que aún teniendo características en común, se plantea una problemática claramente diferente. Las malas hierbas más frecuentes, perniciosas y objeto de este estudio son *Sorghum* y *Green panic*. Estas malas hierbas crecen directamente sobre las líneas de cultivo, muy cerca de las plantas de azúcar, intentando ahogarlas quitándoles los nutrientes y la luz del sol. La figura 5.13 muestra un ejemplo de una imagen tomada en el campo, donde se puede

ver la caña de azúcar (parte superior de la imagen) y cómo las malas hierbas (parte inferior) crecen entremedias.




Figura 5.13: Mala hierba en cultivo de caña de azúcar

Debido a que las malas hierbas crecen entremezcladas con el cultivo, la identificación requiere un análisis de mayor resolución que examine cada línea de cultivo por separado. Además, la aplicación de tratamientos se realiza mediante micropulverización aplicando dosis máxima cada vez que se localiza una planta de mala hierba.

En este caso los métodos de discriminación que se desarrollen tienen que aprovechar las ligeras diferencias en diferencias espectrales (color) y forma de las plantas (la caña de azúcar crece a partir de un único tallo mientras que las malas hierbas crecen de varios a la vez) y posiblemente en la textura de las hojas.

5.2.1. Adquisición de las imágenes

Al igual que en el maíz, las imágenes (vídeo) se toman directamente desde el tractor, a la vez que éste recorre el campo. La gran diferencia en este caso es que las imágenes se adquieren desde una altura muy reducida, y colocando la cámara perpendicular al suelo, ya que se analiza cada planta presente en cada línea de cultivo por separado. La figura 5.14 muestra la forma de adquirir la imagen de vídeo.



Figura 5.14: Método de toma de las imágenes para la detección de mala hierba en tiempo real en caña de azúcar. La cámara se coloca sobre una plataforma enganchada a la parte trasera del tractor

Las imágenes resultantes, figura 5.15, muestran pequeñas zonas de la línea de cultivo, en las que se pueden ver sólo plantas de azúcar (figuras 5.15(b) y (d)), azúcar y malas hierbas entremezcladas (figuras 5.15(a) y (e)) o sólo malas hierbas (figuras 5.15(c) y (f)). Una vez más, los vídeos han sido tomados a lo largo de varios periodos de tiempo en distintos campos, disponiendo actualmente de más de 8 horas de material, asegurando por lo tanto que se tiene una gran variedad de condiciones en el cultivo, mala hierba y la relación entre ambas especies.

La caña de azúcar, a diferencia del maíz o del cereal, tiene varios ciclos de producción durante un mismo año. Puede sembrarse en cualquier momento del año y tarda en crecer más o menos cuatro meses, después de los cuales se recoge y se realiza otra siembra. Esto significa que dependiendo del campo, las operaciones de sembrado, aplicación de tratamientos y cosecha se efectuarán en fechas distintas. Por tanto, los vídeos se toman a lo largo de todo el año, en lugar de en épocas específicas, lo que provoca que el aspecto del cultivo y la mala hierba sea distinto en estados de crecimiento similares, por lo que la variedad de situaciones encontradas en los vídeos recogidos será enorme. Las diferencias de aspecto se agudizan en los cultivos de caña estudiados en Australia ya que éstos se encuentran en zonas de clima subtropical, donde las diferencias climáticas entre la época seca (invierno) y la época de lluvias (verano) son mucho mayores que las encontradas en un clima mediterráneo, ver figura 3.17.

En consecuencia, desde el principio del proyecto de detección de malas hierbas en cultivo de caña se abrieron varias líneas de investigación: a) trabajar de día sin ningún control sobre las condiciones de iluminación (figuras 5.15(a), (e) y (f)), b) trabajar de día tapando la cámara con una cubierta (figura 5.15(d)), con el propósito de reducir la variabilidad de iluminación en la imagen y facilitar el procesamiento, que como se verá es muy sensible a los cambios en iluminación y c) trabajar de noche con iluminación artificial, teniendo un control aún mayor sobre la iluminación (figuras 5.15(b) y (c)).

Una vez más, uno de los requisitos del proyecto es usar un equipo lo más barato posible, que garantice la viabilidad económica de las técnicas una vez desarrolladas. Al tomar las imágenes desde muy cerca, se obtiene mucho más detalle de las plantas, por lo que ni siquiera es necesario utilizar una cámara de vídeo convencional, sino que es suficiente una cámara web buena. Todos los vídeos fueron capturados utilizando una cámara web Logitech Pro, que suministra 25 fps a una resolución de 640x480 píxeles por puerto USB.

5.2.2. Procesamiento

Como la actuación consiste en aplicar la dosis máxima de tratamiento cada vez que se identifica mala hierba, en este caso la etapa de percepción sólo debe detectar la presencia o ausencia de infestación, sin necesidad de realizar una estimación de la

5.2. Detección de malas hierbas en tiempo real en caña de azúcar



Figura 5.15: Ejemplo de frames. Las malas hierbas se encuentran marcadas con pintura naranja para facilitar su reconocimiento a la hora de estudiar los vídeos

densidad de la misma y del cultivo como en los casos anteriores, en los que se quería estimar lo perjudicial que podía ser la infestación para el cultivo y así ajustar la dosis de tratamiento con el fin de conseguir mayor eficacia con menor cantidad de herbicida.

Segmentación

El primer paso consiste una vez más en la segmentación de la vegetación. El método aplicado es **S1**, dejando fijos las constantes asociadas a la combinación lineal a los valores ajustados mediante los algoritmos genéticos y usados también para el maíz ($r = -0,884, g = 1,262, b = -0,311$) y variando el valor de umbral usado (llamado aquí θ_{segm}) del mismo modo que se hacía para el maíz (valor medio de intensidades del frame tras la combinación lineal, visto en la sección 5.1). En la figura 5.16 se muestra el resultado de la segmentación usando un umbral $\theta_{segm} = 245$. Como se puede ver, tanto las constantes asociadas a la combinación lineal halladas mediante el ajuste genético sobre imágenes de cereal y usadas para maíz, como el ajuste del umbral por valor medio de intensidades, funcionan bien también en el azúcar.

El hecho de que las constantes asociadas a la combinación lineal se muestren igual de efectivos tanto en maíz y cereal como en azúcar, nos lleva a pensar en su validez general al menos en el tipo de cultivos analizados. Una explicación al respecto podría ser el hecho de que las cubiertas vegetales en estos cultivos poseen las mismas relaciones espectrales.

Discriminación por color y textura

Para estudiar mejor las posibles diferencias en diferencias espectrales (color), se llevó a cabo un estudio de la reflectancia del azúcar y de cada una de las especies de malas hierbas. Para realizar la medida se utilizó un espectrómetro ASD (Dispositivo Espectral Analítico) con rango de entre 350 nm hasta 1060 nm (visible y NIR). La figura 5.17 muestra el resultado. A primera vista, las mayores diferencias se sitúan en el azul oscuro (450nm), en el amarillo (620nm), y entre el final del rojo y el comienzo del infrarrojo cercano (de 750nm a 850nm).

Analizando, en los primeros vídeos disponibles, la componente azul de aquellos

5.2. Detección de malas hierbas en tiempo real en caña de azúcar




Figura 5.16: Resultado de la segmentación usando el método *S1*. Se utilizan como constantes las obtenidas con el ajuste genético y como umbral el valor medio de las intensidades en el frame resultado de la combinación lineal, en este caso $\theta_{segm} = 245$




Figura 5.17: Reflectancia espectral del azúcar (verde), *Sorghum* (naranja) y *Green panic* (rojo)

frames donde sólo hay malas hierbas o azúcar, se apreciaron rápidamente diferencias evidentes, figura 5.18. Efectivamente, analizando los vídeos se confirmó que tal y como se ve en el espectro, las malas hierbas muestran intensidades en el azul menores que el azúcar, figuras 5.18(c) y (d), por lo que con una sencilla umbralización sobre el plano azul B (umbral $T = 100$, ecuación 5.3) se discriminaba correctamente entre ambas, tal como se muestra en las figuras 5.18(e) y (f).

$$F(x, y) = \begin{cases} \text{Mala hierba} & \text{si } B(x, y) \leq T \\ \text{Azúcar} & \text{si } B(x, y) > T \end{cases} \quad (5.3)$$

Sin embargo, trabajar directamente sobre valores de intensidad hace que el proceso de detección sea muy sensible a los cambios de iluminación, lo que obliga a cambiar el valor del umbral de la ecuación 5.3 para cada vídeo (muestreo) e incluso entre distintos frames de un mismo vídeo si se quieren obtener buenos resultados en el proceso de discriminación. Estas variaciones afectaban al procesamiento de la imagen incluso trabajando con cubierta, que evita los efectos de la iluminación solar. Todo esto obliga a estudiar otro método de discriminación.

Observando más atentamente el espectro, se puede ver que en el rojo las diferencias en intensidad están invertidas con respecto al azul, es decir, esta vez es la mala hierba la que muestra intensidades mayores que el azúcar. En consecuencia, la proporción de azul sobre rojo es muy distinta entre ambos, lo que potencialmente constituye una buena forma de discriminación.

Analizando los vídeos y calculando la proporción de azul sobre rojo (b/r) se aprecia efectivamente que en las malas hierbas las intensidades de rojo son siempre mayores que las de azul, mientras que en el azúcar pasa lo contrario, ver figuras 5.19(c) y (d). En consecuencia, una sencilla umbralización (ecuación 5.4) puede ser una aproximación válida para discriminar correctamente entre ambas especies, tal como se muestra en las figuras 5.19(e) y (f).


5.2. Detección de malas hierbas en tiempo real en caña de azúcar




(a) frame de azúcar




(b) frame de malas hierbas



(c) histograma del plano azul



(d) histograma del plano azul



(e) píxeles identificados como
malas hierbas
siguiendo ecuación 5.3



(f) píxeles identificados como
malas hierbas
siguiendo ecuación 5.3

Figura 5.18: *Discriminación por diferencias en las intensidades del azul. Mediante una sencilla umbralización sobre el plano azul de la imagen segmentada, ecuación 5.3 con umbral $T = 100$, pueden discriminarse correctamente los píxeles pertenecientes a malas hierbas*

$$F(x, y) = \begin{cases} \text{Mala hierba} & \text{si } B(x, y)/R(x, y) \leq \theta_{color} \\ \text{Azúcar} & \text{si } B(x, y)/R(x, y) > \theta_{color} \end{cases} \quad (5.4)$$

Este método tiene la clara ventaja sobre el definido por la ecuación 5.3 de ser mucho más robusto ante cambios de iluminación, ya que cuando cambia la luz, varían ambas intensidades (rojo y azul) manteniéndose la proporción b/r en valores muy parecidos.

Una vez hallados los píxeles pertenecientes a malas hierbas (píxeles rojos), se etiqueta el frame como a **Tratar** si el número de estos píxeles supera un cierto umbral (tomado con respecto al número total de píxeles de la imagen), ver ecuación 5.5. El valor del umbral, θ_{tam} es otro de los parámetros de entrada al procesamiento, pudiéndose ajustar al principio del tratamiento según el tamaño esperado de las plantas de malas hierbas.

$$Frame = \begin{cases} \text{Tratar} & \text{si } numPíxelesRojos(Frame) > \\ & numPíxeles(Frame) * \theta_{tam} \\ \text{No Tratar} & \text{si } numPíxelesRojos(Frame) \leq \\ & numPíxeles(Frame) * \theta_{tam} \end{cases} \quad (5.5)$$

La tabla 5.1 muestra un resumen de los resultados del método sobre algunos vídeos tomados de día, tanto sin controlar la iluminación como colocando una cubierta sobre la cámara. Para cada vídeo se mide el porcentaje de frames que contienen plantas de malas hierbas correctamente etiquetados como a **Tratar** (HIT o Verdadero positivo) o indebidamente como **No Tratar** (MISS o Falso negativo), y el número de frames de plantas de azúcar indebidamente clasificadas como a **Tratar** (FHIT o Falso positivo). Los indicadores objetivo para el rendimiento establecían al principio del proyecto que debía alcanzarse un mínimo del 90 % de verdaderos positivos en la clasificación de frames con mala hierba y esto no teniendo nunca más de 5 % falsos positivos. Los falsos negativos son fallos más peligrosos porque implican no tratar una zona que lo necesita. La tabla 5.1 muestra además los valores de los tres parámetros del procedimiento. Los


5.2. Detección de malas hierbas en tiempo real en caña de azúcar




(a) frame de azúcar




(b) frame de malas hierbas




(c) histograma de la proporción de azul con respecto a rojo b/r



(d) histograma de la proporción de azul con respecto a rojo b/r



(e) separación en *más rojo*
o *más azul*
según la ecuación 5.4



(f) separación en *más rojo*
o *más azul*
según la ecuación 5.4

Figura 5.19: Discriminación por diferencias en la proporción de rojos y azules. El azúcar muestra mayor proporción de azul comparado con rojo, mientras que las malas hierbas tienen mayores intensidades en el plano rojo (umbral usado en este caso $\theta_{color} = 150$)

valores de θ_{color} y θ_{tam} se han ajustado para cada vídeo mediante prueba y error. El valor mostrado de θ_{segm} es el valor medio devuelto por el ajuste automático por media de intensidades durante el procesamiento de todos los frames del vídeo.

Sin Cubierta						
Vídeo	θ_{segm}	θ_{color}	θ_{tam}	$HIT(\%)$	$MISS(\%)$	$FHIT(\%)$
s1(2007)	230	150	0.3	91	9	3
s3(2007)	225	148	0.23	96	4	4
s7(2007)	251	161	0.15	92	8	0
s12(2007)	252	151	0.4	88	12	6
s2_1(2008)	225	130	0.7	97	3	48
s2_2(2008)	226	152	0.33	91	9	5
s4_1(2008)	230	163	0.15	66	33	0
s4_8(2008)	230	146	0.41	77	23	9
Con Cubierta						
Vídeo	θ_{segm}	θ_{color}	θ_{tam}	$HIT(\%)$	$MISS(\%)$	$FHIT(\%)$
c4(2007)	231	150	0.2	100	0	1
c7(2007)	235	153	0.2	100	0	2
c12(2007)	225	134	0.18	92	8	1
c15(2007)	224	142	0.21	100	0	0
c1(2008)	220	120	0.21	72	28	9
c2(2008)	222	131	0.2	95	5	4
c6(2008)	221	132	0.33	63	37	4
c9(2008)	228	167	0.17	84	16	22

Tabla 5.1: Resultados del procesamiento. El nombre de los vídeos se codifica según el año, campo y zona en la que fue tomado

Como puede observarse, el procesamiento funciona muy bien en algunos casos (en verde), mientras que fracasa en muchos otros (en rojo). Sorprendentemente, salvo por un caso aislado (vídeo s12(2007)), sólo falla en los vídeos tomados en el 2008, y en ninguno de los del 2007.

Otro problema es el ajuste de los valores de los dos umbrales (color y tamaño).

5.2. Detección de malas hierbas en tiempo real en caña de azúcar

En los ensayos realizados se han ajustado manualmente, variando mucho de un vídeo a otro. Para el ajuste se ha utilizado un método de prueba y error y todavía no se han identificado las razones que hacen que unos valores funcionen muy bien frente a otros, lo que por ahora limita la automatización completa del proceso de detección. Al igual que en otros casos los cambios de iluminación y de condiciones meteorológicas encontradas (humedad del suelo, estado de las plantas, etc.) son los responsables de la gran variabilidad cromática de las imágenes y de las dificultades encontradas a la hora de ajustar los umbrales. El uso de la cubierta sobre la cámara, suaviza ligeramente estos problemas, permitiendo que los valores de los umbrales sean algo más estables, pero aún así el ajuste sigue siendo una tarea compleja.

En un intento por eliminar los problemas asociados a la iluminación, se llevaron a cabo ensayos durante la noche, usando iluminación artificial. Las luces se montaron sobre la misma plataforma, y se usaron dos focos para conseguir una iluminación más homogénea, figura 5.20. Se probaron dos tipos de luces distintas: a) Faros Solux de 50w y b) leds Luxeon K2. Las primeras dan una luz parecida a la luz del sol, generando muchas sombras y reflejos, figura 5.21, mientras que las segundas consiguen una iluminación más difusa y más fría (más azul), figura 5.22.

La tabla 5.2 muestra los resultados del procesamiento sobre los vídeos nocturnos obtenidos con ambas luces sobre los mismos campos. El ajuste de los parámetros se llevó a cabo, una vez más, mediante prueba y error. La segmentación usada fue exactamente la misma que en los tratamientos diurnos.

Como se puede ver, el procesamiento falla en prácticamente todos los vídeos, al igual que pasaba en los vídeos diurnos del año 2008. El único aspecto positivo de las pruebas nocturnas con respecto a las diurnas es que el ajuste de los valores del umbral de θ_{color} fue mucho más sencillo, ya que los mismos valores de umbral funcionan bien en casi todos los vídeos (aportando en este sentido más estabilidad los leds Luxeon que los faros Solux).

A raíz de estos malos resultados, se llevó a cabo un intenso estudio de todos los vídeos, para intentar llegar a identificar cuáles eran los problemas y comprender sobre todo por qué el procesamiento funcionaba bien en todos los vídeos del año 2007 y mal en casi todos los del 2008.




Figura 5.20: Método de toma de las imágenes para la detección en tiempo real de mala hierba en caña de azúcar de noche. La cámara se coloca sobre una plataforma enganchada a la parte trasera del tractor junto con dos focos orientados al centro de la escena



(a) Solux 50w



(b) iluminación de la escena

Figura 5.21: Iluminación usando dos bombillas Solux 50w

5.2. Detección de malas hierbas en tiempo real en caña de azúcar




Figura 5.22: Iluminación usando dos leds Luxeon K2

Solux						
Vídeo	θ_{segm}	θ_{color}	θ_{tam}	$HIT(\%)$	$MISS(\%)$	$FHIT(\%)$
sn1(2008)	185	130	0.3	88	12	6
sn3(2008)	181	136	0.1	91	9	4
sn6(2008)	182	132	0.2	76	24	14
sn9(2008)	184	125	0.53	65	35	23
Luxeon						
Vídeo	θ_{segm}	θ_{color}	θ_{tam}	$HIT(\%)$	$MISS(\%)$	$FHIT(\%)$
ln1(2008)	190	122	0.3	76	24	4
ln3(2008)	192	125	0.1	81	19	0
ln6(2008)	191	124	0.2	68	32	53
ln9(2008)	188	122	0.53	83	17	2

Tabla 5.2: Resultados del procesamiento nocturno

Caracterización de las dificultades en el procesamiento

Al analizar los vídeos en los cuales el procesamiento dio buenos resultados (todos los del 2007 y algunos del 2008), se descubrió que todos tenían en común haber sido tomados en campos donde las malas hierbas estaban en un estado avanzado de crecimiento, presentando tamaños medianamente grandes.

Esto se corroboró analizando los vídeos en los cuales el procesamiento propuesto no obtenía buenos resultados, siendo la causa que el procesamiento sólo es capaz de detectar positivamente malas hierbas grandes, mientras que falla sobre malas hierbas de tamaño pequeño.

Más concretamente, cuando las malas hierbas presentes en el vídeo son demasiado pequeñas, el procesamiento falla independientemente del valor de θ_{tam} , ya que si dicho umbral se coloca en un valor medio-alto las malas hierbas no se detectan, produciéndose muchos falsos negativos, mientras que si se coloca en un valor bajo, el procesamiento detecta correctamente las malas hierbas pero empieza a detectar erróneamente plantas de azúcar, produciéndose falsos positivos.

La figura 5.3 muestra con un ejemplo el problema. La discriminación no es perfecta, sino que algunos píxeles de azúcar se identifican como malas hierbas y viceversa. Cuando la mala hierba no es lo suficientemente grande, las imágenes resultantes de la discriminación pueden ser muy parecidas en frames de azúcar o de mala hierba, presentando la misma proporción de píxeles de mala hierba (25 % en la figura ejemplo), lo que conduce a errores en la clasificación, ya que si el umbral de θ_{tam} está por debajo de dicha proporción se etiquetará el frame de azúcar erróneamente como a **Tratar** (Falso positivo), y en caso contrario se producirá un falso negativo.

Sin embargo, cuando la mala hierba es suficientemente grande, y a pesar de que algunos de sus píxeles se reconozcan erróneamente como azúcar, basta encontrar el valor adecuado de θ_{tam} (45 % en el ejemplo de la figura 5.3) para reconocer correctamente el frame de malas hierbas como a **Tratar** y el de azúcar como a **No Tratar**. En definitiva, el éxito o fracaso del procesamiento depende exclusivamente de la cantidad de malas hierbas grandes presentes en el vídeo.

Para entender por qué el método de discriminación falla, se analizaron 100.000










Frame de entrada	Píxeles reconocidos como azúcar	Píxeles reconocidos como mala hierba	Proporción mala hierba
Mala hierba grande			 47 %
Azúcar			 24 %
Mala hierba pequeña			 24 %

Tabla 5.3: Problema del procesamiento. Debido a una discriminación entre cultivo e infestación incorrecta, frames de malas hierbas pequeñas y azúcar pueden confundirse entre sí, produciéndose falsos positivos (si se clasifican como mala hierba y por tanto a tratar) o falsos negativos (si se clasifican como zonas limpias de mala hierba y por tanto que no se deben tratar)

frames de sólo azúcar y otros 100.000 de sólo malas hierbas de todos los tamaños, en vídeos de los años 2007 y 2008. Para dicho estudio se usaron sólo vídeos tomados de día con cubierta sobre la cámara, para que las diferencias en iluminación no afectasen demasiado al estudio.

Al analizar las distribuciones de las intensidades en azul y en rojo de azúcar y malas hierbas resultantes, figura 5.23, se comprobó que las diferencias espectrales no son tan grandes como se creía al principio, sino que las diferencias tanto en azul como en rojo son mínimas. Por ejemplo, observando las gráficas de probabilidad acumulada, figura 5.23(b) y (d), se comprueba que situando el umbral en un valor tal que discrimine correctamente el 90 % de las malas hierbas sobre todos los vídeos, se etiquetará como mala hierba también el 60 % del azúcar.


Por último, se vio que las diferencias espectrales respecto de los planos de color son mayores a plena luz del sol que cuando se usa cubierta sobre la cámara o con iluminación artificial. En la figura 5.24, se ve claramente que a plena luz del día y sin cubierta sobre la cámara es fácil distinguir a simple vista el azúcar de la mala hierba por su color, algo complicado de noche con luces suaves Luxeon, donde la diferencia apenas es apreciable. Más aún, utilizar luces suaves obliga a la cámara a aumentar el tiempo de exposición del objetivo, lo cual, junto con el movimiento del tractor causa imágenes movidas. Ahora bien, trabajar a plena luz del día tiene otros inconvenientes en Australia, muchos de ellos relacionados con las altas temperaturas que perjudican a los equipos, por lo que la elección sigue sin estar clara y puede ser conveniente no rechazar los tratamientos nocturno explorando otros tipos de iluminación.

5.2.3. Conclusiones


El procesamiento actual, a pesar de una discriminación incorrecta en muchas situaciones, puede funcionar bien siempre y cuando las fechas de aplicación de tratamientos se retrasen lo más posible respetando los márgenes en los que se asegure que el tratamiento todavía es eficaz, garantizando de este modo que el tamaño de las malas hierbas sea suficientemente grande para que puedan ser localizadas por umbral.

Desde un punto de vista práctico, a pesar de que las cantidades de herbicida necesarias para combatir una infestación tardía son mayores, el ahorro en fitosanitario en


5.2. Detección de malas hierbas en tiempo real en caña de azúcar




(a) histogramas de azul
sobre 100.000 frames



(b) probabilidad acumulada (azul)



(c) histogramas de rojo
sobre 100.000 frames



(d) probabilidad acumulada (rojo)

Figura 5.23: Las diferencias en color entre malas hierbas y azúcar, ante un gran conjunto de condiciones, son muy pequeñas




Figura 5.24: Las diferencias en color entre malas hierbas y azúcar aumentan dependiendo de la naturaleza de la iluminación

explotaciones grandes como las de caña de azúcar todavía puede justificar la aplicación basada en el método de detección propuesto. Una vez presentados los resultados descritos, la compañía azucarera dio por concluido con éxito el proyecto (NCEA, 2008) y ha planificado la aplicación real del sistema desarrollado sobre campos en estado avanzado de desarrollo (entre 3 y 4 semanas desde la siembra) para este año 2009.

El método de trabajo será de día y con cubierta, y los valores de los umbrales de θ_{color} y θ_{tam} se ajustarán mediante prueba y error (calibrado del sistema) al principio de cada línea, estando el tractor parado y enfocando la cámara a una planta de azúcar. Para facilitar al operario el calibrado, se ha desarrollado una interfaz gráfica de usuario (GUI), que permite ver el resultado del procesamiento y variar los umbrales sobre la marcha, figura 5.25. Usando la GUI, el operario puede modificar el valor de θ_{color} hasta que el número de píxeles detectados como mala hierba sobre la planta de azúcar enfocada sean mínimos. El valor de θ_{tam} se ajusta en función del tamaño esperado de las malas hierbas en el campo. Este parámetro se establecerá con facilidad ya que todas las malas hierbas encontradas en los campos a tratar serán grandes (estado avanzado de desarrollo).

5.2. Detección de malas hierbas en tiempo real en caña de azúcar




Figura 5.25: Interfaz gráfica de usuario para el ajuste de los parámetros del procesamiento en el sistema de detección de malas hierbas en cultivos de azúcar

Capítulo 6

Actuación

No basta saber, se debe también aplicar. No es suficiente querer, se debe también hacer.

Johann Wolfgang Von Goethe

Una vez recogida la información necesaria sobre el cultivo en el campo (etapa de percepción), el siguiente paso en el ciclo de la AP, figura 2.2, es la interpretación de dicha información de modo que se pueda realizar la toma de decisión para llevar a cabo una actuación precisa sobre el campo (etapa de actuación).

En el caso de la aplicación selectiva de tratamientos, para la etapa de actuación la toma de decisión deberá determinar cómo llevar a cabo la aplicación de fitosanitarios, en función de la naturaleza del cultivo a tratar, las especies de malas hierbas encontradas y otra información que se puede extraer a partir de los datos recogidos en la etapa de percepción, como por ejemplo el estado de crecimiento del cultivo.

En este capítulo se estudian los tipos de equipos de tratamiento y posibles técnicas de pulverización, para a continuación explicar el diseño y funcionamiento del controlador sobre la barra de tratamientos implementado, y publicado en Burgos-Artizzu et al.

(2007). Asimismo se describe la electrónica desarrollada para poner a punto el sistema de aplicación de tratamientos.

6.1. Equipos de tratamiento y técnicas de pulverización

Los herbicidas o fitosanitarios son sustancias químicas que pueden matar o suprimir el crecimiento de ciertas plantas no deseadas. A la hora de controlar una infestación, hay que tener en cuenta que no todas se comportan de igual forma, por lo que el tratamiento deberá enfocarse de modo diferente para cada una de ellas. Además, dada la toxicidad de los herbicidas, es importante que su aplicación se lleve a cabo con cuidado, conociendo desde el principio la naturaleza de la infestación para efectuar un control lo más eficiente, barato, seguro y limpio posible.

A pesar de que la aplicación de herbicidas es una operación sencilla en sí misma, son muchos los factores a tener en cuenta para determinar qué producto utilizar, en qué dosis y en qué momento. El primer paso es conocer la naturaleza de la mala hierba a tratar. Si es de hoja ancha u hoja angosta; si es de ciclo de vida anual, bianual o perenne; si tiene estructuras vegetativas de reproducción, etc. Todo esto permitirá elegir el momento óptimo de la aplicación (herbicidas de presiembra, preemergencia o posemergencia), el producto más adecuado (herbicidas selectivos o totales; herbicidas de contacto o de acción interna; herbicidas latifolicidas o graminicidas, etc.) y ajustar correctamente el equipo de tratamiento (tamaño y tipo de las boquillas, presión de trabajo, tipo de bomba, volumen de aplicación, cantidad de agua en la solución, velocidad de avance, etc.).

Por ejemplo, la figura 6.1 muestra cómo el estado de crecimiento del cultivo y de las malas hierbas (altura y densidad) determinan la cantidad de tratamiento que será necesario aplicar, debido a que evidentemente cuanto mayor sea la densidad de la infestación más herbicida se necesitará.

Otro ejemplo es cómo, según el tipo de herbicida usado, la cantidad de agua con la que se debe mezclar varía mucho. Cuando se aplica un producto de *suelo activo* (producto cuya absorción tiene lugar en las raíces), es conveniente aumentar el volumen de agua, ya que se necesita que el producto se ubique en un determinado lugar del suelo

6.1. Equipos de tratamiento y técnicas de pulverización




Figura 6.1: Volumen de aplicación según el estado de crecimiento del cultivo, variando entre 100 y 300 l/ha. Las escalas de Feekes y Zados determinan el estado de desarrollo de un cultivo según el aspecto exterior

y con buena humedad. Lo mismo ocurre si se aplica un herbicida de contacto (sólo afecta a las partes de la planta con las que entra en contacto), para que el producto cubra la mayor superficie foliar posible. Sin embargo, si se usa un herbicida de acción interna (son las hojas de la planta las que absorben el herbicida y una vez dentro tiene la capacidad de moverse por los tejidos conductores de la planta hacia los puntos de crecimiento donde ejerce su acción letal) la cantidad de agua puede ser menor, ya que sólo se necesita como vehículo de ingreso en la planta.

El tipo de equipo de tratamiento usado también varía mucho dependiendo de la naturaleza del herbicida, del tipo de cultivo, de la superficie a cubrir, etc., figura 6.2. Si la superficie a tratar es pequeña, el herbicida se puede aplicar manualmente, usando un “pulverizador mochila”, figuras 6.2(a) y (d). Sin embargo, cuando la superficie a tratar es muy grande, se utilizan tractores y otro tipo de vehículos. La figura 6.2(b) muestra una aplicación de herbicida en viñedos, usando un rociador por inyección de aire que asegura que el herbicida llega también a las zonas altas del arbusto con una distribución uniforme. Las figuras 6.2(c), (e) y (f) muestran aplicaciones más convencionales mediante barra de tratamientos sobre lechugas, melones y maíz, respectivamente.

Como se puede ver, el tipo de barra de tratamiento usado también varía según el tipo de cultivo.



Figura 6.2: Tipos de equipos de tratamiento usados en distintos cultivos

Otras decisiones fundamentales en la tarea de tratamiento son la elección del tipo de boquilla y presión de trabajo idóneos, figura 6.3. Cada tipo de boquilla produce una superficies de aplicación distinta, además de tener tamaños y ángulos diferentes. La boquilla de chorro en abanico, figura 6.3(a) es la más conocida y usada aunque según el tipo de malas hierbas (hoja ancha o angosta, tamaño, altura, etc.) a tratar y

6.1. Equipos de tratamiento y técnicas de pulverización

las condiciones metereológicas en el momento de la aplicación (viento, humedad, etc.), puede ser recomendable el uso de otras boquillas e incluso combinar varios tipos a la vez.




Figura 6.3: Tipos de boquillas, forma de su superficie de aplicación y rango de presiones normales de trabajo

La presión de trabajo, a su vez, determinará el tamaño de las gotas creadas por la boquilla (cuanta más presión más pequeñas serán las gotas) siendo la elección del tamaño de gota muy importante para obtener el efecto deseado, véase tabla 6.1.

Por supuesto, el tipo de boquilla usado, junto con el estado de crecimiento del cultivo determinarán la altura a la que habrá que colocar los brazos de la barra de tratamiento, figura 6.4.

Por último, la aplicación de tratamientos debe siempre llevarse a cabo bajo buenas

Características	Gotas grandes	Gotas pequeñas
Evaporación	alta	baja
Sensibilidad al viento	alta	baja
Anexo directo a las hojas	bueno	malo
Cobertura	bueno	mala
Penetración	mala	bueno
Inercia de la gota	baja	alta

Tabla 6.1: Características de los distintos tamaños de gota




Figura 6.4: Altura de los brazos

6.1. Equipos de tratamiento y técnicas de pulverización

condiciones meteorológicas, ya que los factores ambientales, tales como la temperatura y humedad relativa del aire determinarán el tipo de reacción de las plantas a los estímulos o tratamientos externos. En este contexto, las recomendaciones básicas de aplicación son las siguientes (Talavera, 2006):

- **Temperatura:** debe aplicarse con temperatura inferior a $30^{\circ}C$.
- **Humedad:** La recomendación es aplicar con humedad relativa del aire superior al 60 %, para evitar el secado de las gotas de pulverización. Además, con baja humedad las plantas se encuentra en estado de estrés por lo que es necesaria más cantidad de herbicida para que se produzca la penetración.
- **Viento:** La velocidad del viento no debe sobrepasar los $10Km/h$, asegurando así que el producto aplicado llegue al objetivo y no se produzca deriva (transporte de las gotas de pulverización a otras áreas no deseadas).
- **Lluvia:** Se recomienda no aplicar con amenaza de lluvia, ya que la lluvia lava el producto, con la posibilidad de infiltrarse en el subsuelo o llegar a aguas subterráneas, contaminándolas. Además, cada herbicida tiene un tiempo de absorción, por lo que la planta no absorberá el producto si se producen lluvias antes de que haya transcurrido ese tiempo.
- **Horario:** El horario varía dependiendo de la época del año. Por ejemplo en verano es recomendable aplicar en las primeras horas del día hasta aproximadamente las 10:00 y en las últimas horas de la tarde a partir de las 17:00, evitando las horas más calurosas del día. Sin embargo, en invierno (cereal de invierno) es aconsejable utilizar las horas centrales del día, ya que el rocío de la mañana altera la absorción y a última hora también aumenta la humedad en el ambiente.

6.1.1. Equipos autónomos de tratamiento

Para llevar a cabo una aplicación selectiva de tratamientos, es necesario que el equipo de tratamiento esté diseñado de modo que pueda ser controlado desde un ordenador, para realizar la aplicación de tratamientos en el campo a partir de las decisiones tomadas en función de la información recogida en la etapa de percepción.

El desarrollo de equipos de tratamiento autónomos, a pesar de ser algo necesario para la aplicación real de tratamientos selectivos, no es en la actualidad un campo de investigación muy activo. Esto es debido a que el desarrollo de equipos de tratamiento autónomos sólo tiene sentido si se dispone anteriormente de una etapa de percepción eficaz, y como ya se ha comentado varias veces a lo largo de esta tesis, la enorme variabilidad encontrada en el campo y la dificultad de la tarea de discriminación, hacen que a día de hoy sean muy pocos los trabajos que se encuentran en condiciones de producir una transferencia tecnológica real (Slaughter et al., 2008).

Uno de los primeros equipos de tratamiento autónomo desarrollados fue el propuesto en Lee et al. (1999) para cultivos de tomate. Este equipo consta de una línea de 8 boquillas de chorro de abanico (colocadas en dos filas de cuatro), que cubren 10cm de ancho. Cada boquilla se activa independientemente mediante señales eléctricas, y el equipo trabaja a dosis fija. Este equipo de tratamiento va montado en un vehículo autónomo, que se mueve entre líneas de cultivo y detecta las malas hierbas en tiempo real, figura 6.5. En definitiva, cada boquilla se activa independientemente según la detección obtenida por el sistema de percepción que discrimina las plantas de tomate de la infestación por diferencias en la forma, tamaño y color de las hojas. Este sistema, con otros algoritmos de visión se ha probado hace poco en campos de algodón (Lamm et al., 2006). Sin embargo, los resultados obtenidos no han demostrado la viabilidad económica del sistema, razón por la que no se ha comercializado. Además del coste asociado, este sistema presenta problemas como la lentitud del vehículo (la velocidad de desplazamiento máxima es de $1,2Km/h$) y la baja precisión, ya que en las pruebas llevadas a cabo en campos reales trata correctamente en media sólo el 47,6 % de las malas hierbas.

Otro enfoque es la automatización de una barra de tratamientos para que ésta pueda ser controlada desde un ordenador. En Tian (2002) se presenta el diseño y la automatización de una barra de tratamiento de 8 secciones independientes para ser controlada desde un ordenador. Las secciones de la barra se activan en función de la salida de un sistema de percepción, que utiliza dos cámaras y parámetros conocidos a priori (espacio entre líneas, ancho de las hojas del cultivo, etc.) para estimar la densidad de la infestación presente mediante una simple segmentación de vegetación en las imágenes. El equipo trabaja con 4 posibles dosis (10 %, 33 %, 66 %, 100 %) ya que el espacio entre líneas de cultivo abarca 4 secciones (formada cada una por dos

6.1. Equipos de tratamiento y técnicas de pulverización




Figura 6.5: Sistema autónomo para tratamiento de malas hierbas en tomate (Lee et al., 1999)

boquillas). Sin embargo, el hecho de estimar la densidad de herbicida a partir de datos conocidos y calibrados a priori hace que no sea un sistema robusto, siendo difícilmente aplicable ante variedad de situaciones o utilizable en distintos cultivos.

Trabajos más recientes llevan a cabo un enfoque más sencillo, usando pulverizadores puntuales formados por una sola boquilla que cubre sólo el espacio entre líneas de cultivo, montados sobre tractores convencionales y controlados mediante señales eléctricas. En Rizzardì et al. (2007) cada boquilla se activa o no, a dosis fija, según la salida de un sensor optoelectrónico. En Loghavi y Mackvandi (2008), se controlan las boquillas abriendo o cerrándolas, también a dosis fija, a partir de la información contenida en un mapa de infestación generado con anterioridad mediante un muestreo discreto manual.

Por último, destacar el robot agrícola desarrollado por Astrand y Baerveldt (2002) para control selectivo de malas hierbas en remolacha en invernaderos, capaz de detectar las malas hierbas por diferencias en forma y tamaño usando redes neuronales, aunque en este caso el control de las malas hierbas es mediante escarda, con un brazo mecánico que arranca las malas hierbas.

6.2. Automatización de la barra de tratamientos

Para llevar a cabo la aplicación selectiva de fitosanitario, suministrando en cada punto la dosis de herbicida deseada, hay que ser capaces de controlar en tiempo real una barra de tratamientos. En este caso, se ha realizado la automatización de una barra de tratamientos comercial, para controlar la aplicación desde un ordenador.

6.2.1. Descripción de los componentes del sistema

La barra de tratamiento usada es una HARDI NK, de 10 metros de longitud, con 5 secciones de 2 metros cada una con control de apertura y cierre independiente, figura 6.6. El equipo consta además de un depósito de 400 litros, de una bomba que lleva el líquido hasta los brazos de pulverización, de las válvulas de agitación y seguridad, de los motores de apertura/cierre de cada sección del distribuidor de producto, figuras 6.7 y 6.8, así como de una caja de control (ver figura 6.14) que permite activar y desactivar

6.2. Automatización de la barra de tratamientos

las secciones, cambiar la cantidad de producto, etc. Además, la barra dispone de un dispositivo (Hardi-Matic) que permite ajustar la dosificación a la velocidad del vehículo para asegurar la uniformidad en el tratamiento. El control de apertura y cierre es simultáneo, de modo que en el mismo instante pueden estar abiertas varias secciones de la barra mientras el resto permanecen cerradas. Es importante resaltar que, en una situación como la descrita, todas las secciones abiertas tendrán el mismo caudal.




Figura 6.6: La barra HARDI NK consta de 5 secciones independientes de 2 metros cada una

La figura 6.9 muestra en detalle el distribuidor. Éste está compuesto de cinco motores eléctricos que giran en un sentido o en otro según las señales de entrada, abriendo o cerrando cada una de las secciones de la barra, y del motor de regulación de caudal, que también gira en dos sentidos según la señal de entrada, aumentando o disminuyendo la cantidad de producto, figura 6.10. Los cinco motores de control de sección llevan finales de carrera, de manera que cuando han girado todo lo posible se paran. El motor asociado al caudal gira continuamente mientras se mantiene pulsado. Todos los motores trabajan con una diferencia de potencial de 12V, y consumen una intensidad variable mientras están girando con un máximo de 450mA.

El equipo de tratamientos se monta en un tractor convencional conectándolo al eje




Figura 6.7: Partes de las que se compone la barra de tratamiento HARDI NK




Figura 6.8: Diagrama del depósito, el distribuidor con motores de apertura/cierre de cada sección y enganche de la barra

6.2. Automatización de la barra de tratamientos




Figura 6.9: Distribuidor de producto de la barra




Figura 6.10: El sentido de giro de los seis motores de la barra se controla aplicando una diferencia de potencial de 12V o -12V

de fuerza de 700 revoluciones por minuto, figura 6.11, poniendo en marcha la bomba del equipo. Los motores se alimentan desde la batería del tractor.




Figura 6.11: El equipo de tratamientos se conecta a un eje de fuerza

Cada sección de la barra tiene cinco boquillas de chorro en abanico, figura 6.12, las habitualmente usadas en la aplicación de herbicidas en maíz, aunque son fácilmente sustituibles por otro tipo de boquillas.

6.2.2. Circuito electrónico de control

El equipo dispone de un sistema de control sobre las secciones abiertas, el volumen de aplicación, etc., cuyo esquema se muestra en la figura 6.13. Está compuesto de una caja de control con una botonera que permite controlar la apertura y cierre de cada una de las secciones de la barra, el encendido/apagado general del equipo, y el caudal de producto aplicado, entre otras funciones.

Con la situación de partida descrita, el primer objetivo es diseñar y desarrollar la electrónica que permita el control de los motores desde un PC convencional. Una vez

6.2. Automatización de la barra de tratamientos




Figura 6.12: Cada una de las secciones de la barra contiene 5 boquillas en chorro de abanico




Figura 6.13: Diagrama del controlador 2500 incluido en la barra

conectado el equipo al PC se implementará una interfaz con las mismas funcionalidades que la caja de control. La figura 6.14 muestra en detalle la caja de control y las funciones principales que tienen que estar disponibles en la interfaz que se desarrolle.



Figura 6.14: Caja de control de la barra HARDI NK y sus funciones principales

Para poder controlar la apertura o cierre de las secciones desde un ordenador, es necesario transformar las órdenes del ordenador en una diferencia de potencial de 12V en el sentido deseado. Esto se ha conseguido gracias a una tarjeta de adquisición de datos (DAQ), que traduce las órdenes del ordenador en 0 o 5V, y al diseño de un circuito electrónico, que convierte las salidas de la DAQ en la diferencia de potencial necesaria para que se muevan los motores. La figura 6.15 muestra una representación esquemática del sistema completo. El ordenador se comunica con los motores a través de la DAQ y el circuito, formado por los puentes de control LMD18200 de los motores, los optoacopladores que permiten separar la parte electrónica de la parte de potencia y el Circuito Lógico Programable Complejo (CPLD) que gestiona la comunicación entre la DAQ y el circuito.

En la figura 6.16 se puede ver el esquema del diseño del circuito desarrollado. Además del control sobre los motores, dispone de un interruptor de apagado/encendido

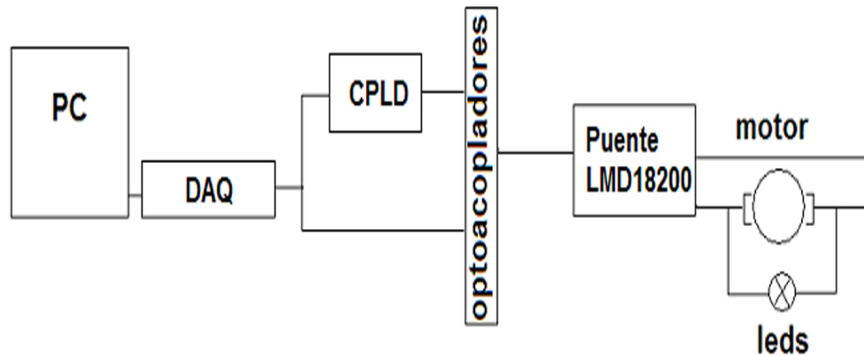


Figura 6.15: Esquema del sistema de control

general (que se puede usar como mecanismo de seguridad conectado a una seta) y de un conjunto de 3 leds por motor (leds de estado verde, ámbar y rojo), que informan sobre el estado de cada sección de la barra (apertura, cierre y error, respectivamente).

Control de los motores

El control del sentido de giro del motor, se ha resuelto utilizando un puente LMD18200, figura 6.17, que permite también registrar información tal como sobrecalentamiento o intensidad consumida en cada momento. Este puente se ha escogido frente a otras posibles opciones, como el SN7544, por las ventajas que presenta:

- Es suficiente con un bit de indicación de sentido, mientras que el SN7544 necesita 2.
- Incluye protección interna frente a picos de intensidad, no siendo necesario montar un puente de diodos para absorberlos.
- Tiene un flag de temperatura que se activa cuando hay sobrecalentamiento.
- Tiene un pin para medir intensidad consumida.

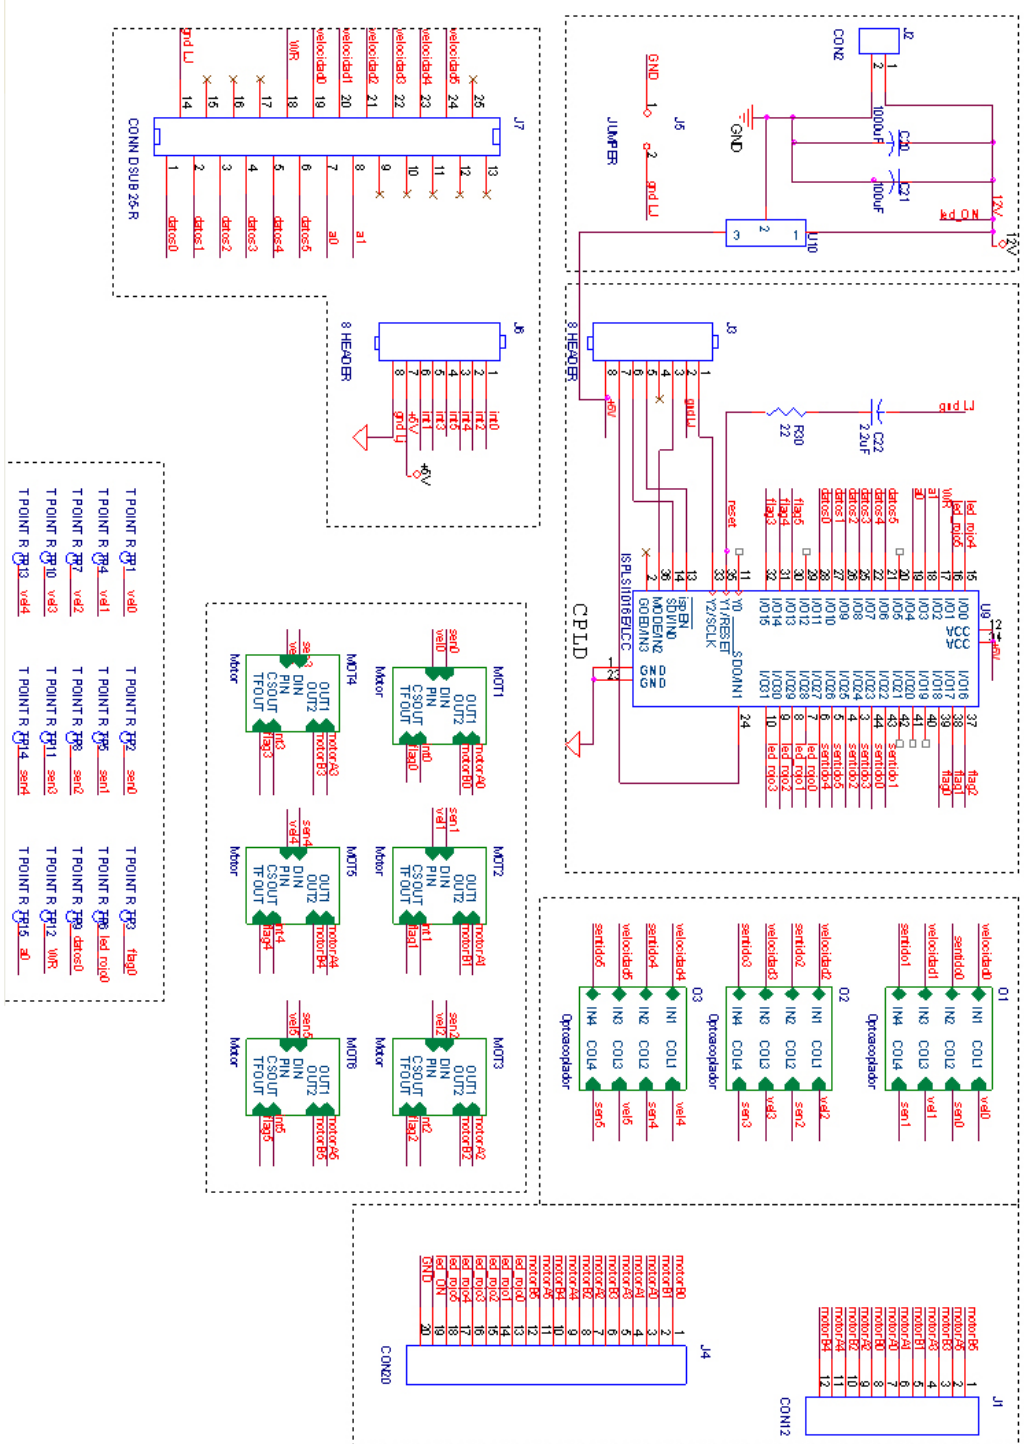


Figura 6.16: Esquema del circuito de control diseñado

6.2. Automatización de la barra de tratamientos

- Permite variar la velocidad del motor con distintos anchos de pulso e incluso frenarlo.

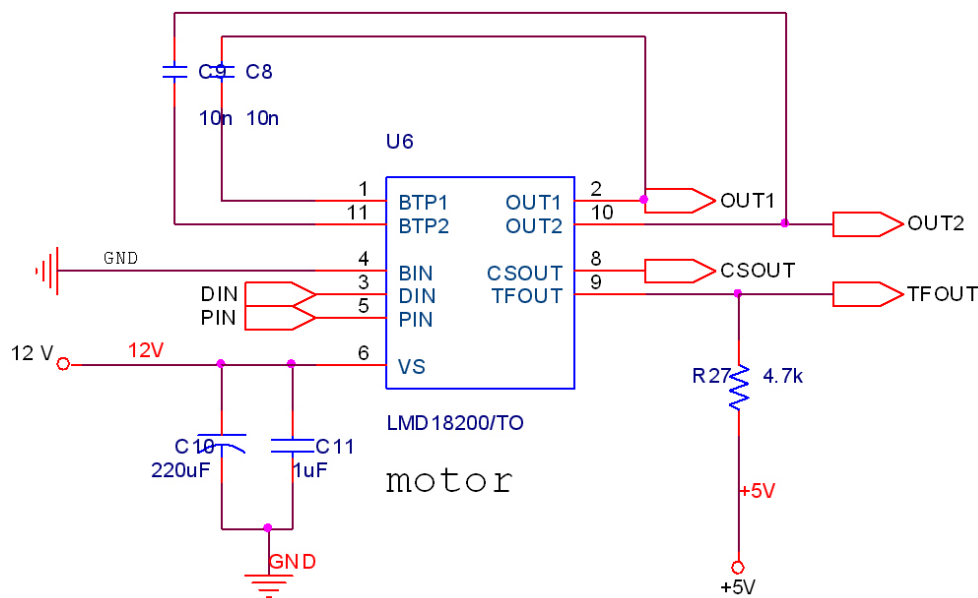


Figura 6.17: Esquema del puente LMD18200

Conexión al ordenador

Para el enlace entre el circuito implementado y el ordenador se ha usado una tarjeta de adquisición de datos LabJack U12, con entradas y salidas digitales y analógicas, figura 6.18. Las órdenes de apertura dadas por el ordenador se traducen en nivel alto (5V) o bajo (0V) en las salidas digitales de la tarjeta de adquisición que está conectada al ordenador a través del puerto USB. Estas señales pasan posteriormente por optoacopladores para separar la parte electrónica de la parte de potencia.

Ahora bien, la tarjeta Labjack U12 consta de 20 entradas/salidas que no son suficientes, ya que son necesarias un total de 24 entradas digitales y 6 salidas analógicas, tal como se detalla a continuación:

- 6 entradas analógicas para medir la intensidad consumida




Figura 6.18: Tarjeta de adquisición de datos Labjack U12

- 6 entradas digitales para detectar sobrecalentamiento
- 6 salidas digitales para indicar el sentido de giro de los motores
- 6 salidas digitales para controlar la velocidad de giro de los motores
- 6 salidas digitales para encender los leds rojos de sobrecalentamiento

Para resolver este problema se ha incluido en el circuito un CPLD (ispLSI 1016, de la marca Lattice), figura 6.19, que permite, al ser reprogramable, dejar la puerta abierta a futuras mejoras sin tener que realizar cambios en el circuito.

El vector de 6 bits *datos*, actúa como entrada o salida de la DAQ, dependiendo de la opción que se escoja en cada momento por medio de los dos bits de *selección* y el bit de *lectura/escritura*. Estos bits permiten que la información del vector datos sea copiada en el vector de salida del CPLD *sentido*, en el vector *led sobrecalentamiento*, o que el vector de 6 bits *flag temperatura* sea copiado en el vector *datos*, y por lo tanto transmitido al ordenador como entrada de la DAQ.

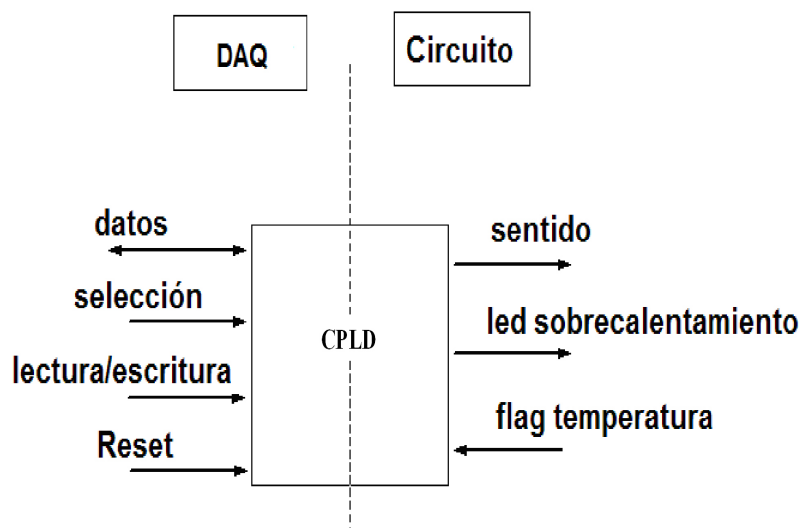


Figura 6.19: CPLD para la redistribución de las entradas/salidas de la DAQ

Los 6 pines de *sentido* están conectados a los 6 puentes, ordenando abrir boquillas al motor correspondiente cuando el bit enviado por el CPLD está a nivel alto (5V), o cerrar cuando está a nivel bajo (0V). Los 6 bits de *led sobrecalentamiento* encienden el led rojo asociado a cada motor si hubiera sobrecalentamiento en dicho motor. Los 6 bits de *flag temperatura* también están conectados a los puentes y actúan como entradas, registrando si el *flag de temperatura* de cada uno está a nivel alto (sobrecalentamiento del motor) o bajo. Estos 3 vectores (*sentido*, *led* y *flag*) nunca se usarán al mismo tiempo sino que con los dos bits de *selección* se podrá establecer cuál funciona en cada momento. Además, la entrada *Reset* permite poner a cero inicialmente todas las salidas del CPLD, evitando que se produzcan movimientos de los motores al conectar la alimentación.

Con la utilización del CPLD se consiguen cumplir los requisitos de diseño para el circuito utilizando solamente 10 entradas/salidas digitales de la tarjeta de adquisición, dejando 10 entradas/salidas digitales disponibles, que se podrán utilizar en ampliaciones futuras como por ejemplo para actuar sobre el variador de velocidad del tractor.

Leds

Cada motor tiene asociado tres leds:

- **Led verde:** si está encendido indica que el motor correspondiente está girando en sentido de apertura de las boquillas.
- **Led ámbar:** si está encendido indica que el motor correspondiente está girando en sentido de cierre de las boquillas.
- **Led rojo:** el ordenador da la orden de encendido cuando le llega información de que se ha sobrecalentado un puente.

Los leds de apertura y cierre están conectados en paralelo a los bornes del motor, lo que permite que se enciendan mientras giran, pero los mantiene encendidos cuando el motor termina de girar ya que aunque llegue a un final de carrera, la diferencia de tensión en bornes se mantiene. Para evitar eso, y que los leds sólo estén encendidos con el motor girando, desde el ordenador se envía una orden de frenado al puente de control de motor, que pone ambos bornes a la misma tensión, haciendo que los leds se apaguen. Además, el circuito dispone de otro led adicional que indica el estado (encendido/apagado) general del equipo.

El circuito está dividido en dos placas, figura 6.20. En la superior se encuentran sólo los leds de estado, mientras que en la inferior se confina el cableado y los componentes necesarios para la comunicación con el PC y los motores. La placa inferior está conectada a la placa superior para permitir el encendido de los leds. La principal ventaja de la separación en dos placas es la mejor distribución de las placas dentro de una caja para poder situar los leds en una posición de máxima visibilidad.

6.2.3. Pruebas en laboratorio

El circuito ha sido probado en laboratorio, para evaluar su funcionamiento. Las pruebas se han realizado en el laboratorio conectando la barra a un motor eléctrico que reproduce el funcionamiento del eje de fuerza del tractor (movimiento de rotación de

6.2. Automatización de la barra de tratamientos




Figura 6.20: Placas del circuito final

aproximadamente 700 revoluciones por minuto), figura 6.21, permitiendo realizar una evaluación de un modo limpio, sencillo y seguro antes de ir al campo.

Finalmente, se ha desarrollado un programa en C++ para controlar el circuito desde el ordenador a través de la tarjeta de adquisición de datos. El programa se ha implementado en el entorno de programación Borland, usando las librerías proporcionadas con la tarjeta Labjack U12, y se maneja a través de una GUI (Interfaz Gráfica de Usuario) que simula la caja de control de la barra HARDI NK, figura 6.22, que además permanece disponible para controlar el equipo si fuese necesario.

Con la GUI implementada se ha comprobado el funcionamiento de cada parte del circuito, abriendo y cerrando distintas secciones de la barra en cada instante, y controlando también el caudal aplicado. En las pruebas el depósito se llenó con agua. Además, como se verá en las siguientes secciones, las funciones implementadas en la GUI son el punto de partida para incluir un sistema de control que decida las secciones a abrir y cerrar así como las dosis a aplicar en función de la información que se tiene del campo (mapas de infestación y/o detección en tiempo real).




Figura 6.21: Alimentación de la barra usando un motor eléctrico

Figura 6.22: Interfaz Gráfica de Usuario del programa desarrollado para controlar la barra desde el ordenador con las mismas funcionalidades de la caja de control de la barra HARDI NK

6.3. Controlador borroso multivariable para el ajuste de tratamientos

Una vez automatizada la barra de tratamientos para su control desde un ordenador, el siguiente paso es el diseño y desarrollo de un controlador para el ajuste de tratamientos.

6.3.1. Requisitos del controlador

El controlador debe ser capaz de decidir qué cantidad de herbicida aplicar en cada momento, basándose en la información del entorno proporcionada por el sistema de percepción. Más concretamente, el controlador calculará las necesidades en términos de herbicida de cada punto basándose en dos conjuntos de valores recibidos (por punto) como entrada: el *Índice de Cobertura de malas hierbas* (IC) y el *Estado de Crecimiento del cultivo* (EC). El primer valor suministra información de la densidad de la infestación presente en el campo, mientras que el segundo es necesario para poder ajustar convenientemente la dosis de herbicida, ya que ante valores idénticos de IC, la infestación es potencialmente más peligrosa en estados de crecimiento del cultivo tempranos que en estados de crecimiento del cultivo avanzados; no sólo porque la infestación pueda multiplicarse al crecer el cultivo sino también porque un cultivo incipiente es más frágil que uno bien desarrollado.

El controlador ajusta la cantidad de herbicida a aplicar actuando sobre la apertura/cierre de cada una de las secciones de la barra, el caudal de pulverización de herbicida y la velocidad del tractor. La velocidad del tractor ha sido incluida en el control porque representa una forma de actuación sobre la dosificación más sencilla de medir y controlar que el caudal de pulverización de la barra. A caudal fijo, una mayor velocidad de avance se traduce en una aplicación de menor dosis por punto frente a la dosificación obtenida con velocidades más bajas.

La figura 6.23 muestra las entradas y salidas del controlador. Las entradas serán IC y EC, así como los valores anteriores de caudal y velocidad. Las salidas son el caudal, la velocidad y el estado de las secciones de la barra (apertura o cierre de cada una). Las salidas del controlador velocidad y caudal, se han definido como valores de ajuste

(aumentar/disminuir) sobre los valores de entrada, de modo que los valores reajustados realimentan la siguiente iteración del controlador. El caudal de pulverización se mide en l/min y la velocidad del tractor en Km/h .

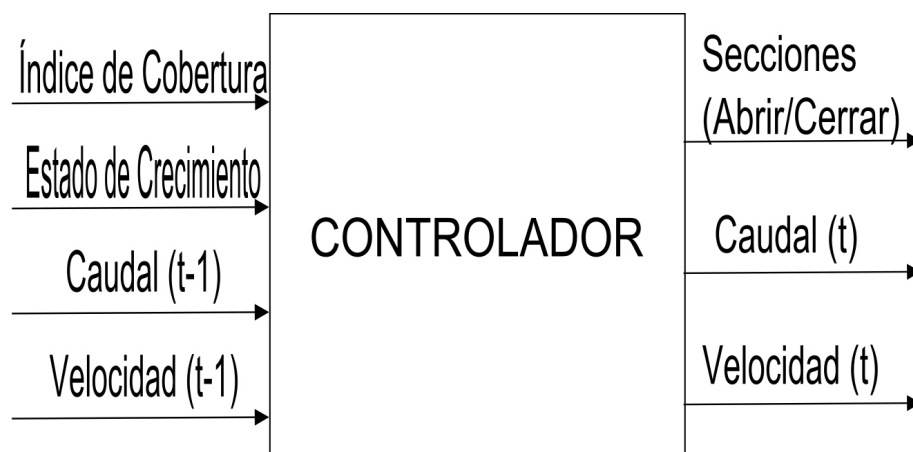


Figura 6.23: Entradas y salidas del controlador

Un requisito muy deseable (y muy extendido) para cualquier controlador es que produzca el menor número posible de cambios en los actuadores que controla, es decir, que realice mínimas variaciones sobre la salida. En este caso, además, resulta más conveniente actuar sobre la velocidad que sobre el caudal, ya que el variador de velocidad es flexible, preciso y robusto, mientras que el regulador de caudal de la barra de tratamiento está expuesto a mayor inestabilidad. Además, los cambios sobre el caudal afectan de forma directa al tamaño de gota, que debe permanecer constante a lo largo de todo el tratamiento. Por tanto, se ha supuesto que siempre que se deba reducir/aumentar la cantidad final de herbicida aplicada, es mejor aumentar/reducir la velocidad que reducir/aumentar el caudal. Por supuesto, esta estrategia puede variarse construyendo otro controlador también siguiendo la metodología que se propone a continuación.

El controlador se ha diseñado teniendo en cuenta el tractor donde puede ser usado, un vehículo de la casa John Deer (el mismo utilizado para la adquisición de los vídeos en tiempo real en maíz, ver Capítulo 5). Es importante destacar que el motor de este tractor, igual que el de muchos tractores modernos, funciona en régimen constante de revoluciones por minuto, denominado toma de fuerza, por lo que la variación de

velocidad en este tipo de vehículos no se realiza a través de un actuador continuo (acelerador), como en los coches, sino de un variador de velocidad discreto, que sólo permite un conjunto determinado de valores, lo que debe tenerse en cuenta en la etapa de diseño del controlador, ya que para la variable velocidad no son posibles todos los valores de salida.

6.3.2. Descripción del controlador borroso propuesto

El controlador recibe como entrada las dos variables creadas por el sistema de visión, el último caudal utilizado y la velocidad actual del tractor, y a partir de estos datos controla la cantidad y distribución de herbicida actuando: 1) sobre la barra de tratamiento, modificando el caudal y abriendo o cerrando las distintas secciones, y 2) sobre el variador de velocidad del tractor, modificando la velocidad de avance del tractor. Debido a la independencia de la apertura y cierre de cada sección, y a que cada una cubre un área bastante grande (2 m), el sistema propuesto razona independientemente sobre cada una de las secciones de la barra. Así, en cada instante el controlador procesará de forma independiente 5 zonas distintas (5 valores de Índice de Cobertura y 5 valores de Estado de Crecimiento), generando el control de apertura o cierre para cada una de las 5 secciones. Los 5 valores de entrada de IC y EC darán lugar también a 5 valores distintos de caudal y velocidad, cuando en realidad ambos valores deben ser los mismos para las 5 secciones. Por tanto, y para asegurar una aplicación de herbicida en exceso mejor que en defecto, el controlador ajustará la velocidad al mínimo de las 5 velocidades calculadas y el caudal al máximo de los 5 valores de caudal calculados.

Para el diseño del controlador no se dispone inicialmente de ningún modelo del comportamiento que debe seguir ni ningún modelo del sistema a controlar. Lo único que se tiene es el conocimiento del experto, es decir, se puede conocer la conducta de un operario experimentado que, conduciendo el tractor, tuviese control sobre la barra de tratamiento. Este tipo de conocimiento es muy difícil de plasmar en un controlador clásico, ya que se compone de reglas intuitivas y con incertidumbre. La Teoría de Conjuntos Borrosos formulada por Zadeh (1965) y la teoría básica presentada posteriormente para el diseño de Controladores Borrosos (Zadeh, 1973), resulta de gran utilidad en casos como éste (Lee y Dexter, 2001).

La teoría de conjuntos borrosos se basa en que los conjuntos poseen límites imprecisos, permitiendo que los objetos puedan pertenecer o no a cada conjunto, o a ambos a la vez dentro de un intervalo de confianza $[0,1]$, lo que da lugar a funciones de pertenencia graduales, figura 6.24(b), en contraposición con la teoría de conjuntos clásica que sólo contempla la pertenencia o no pertenencia a un conjunto, figura 6.24(a).

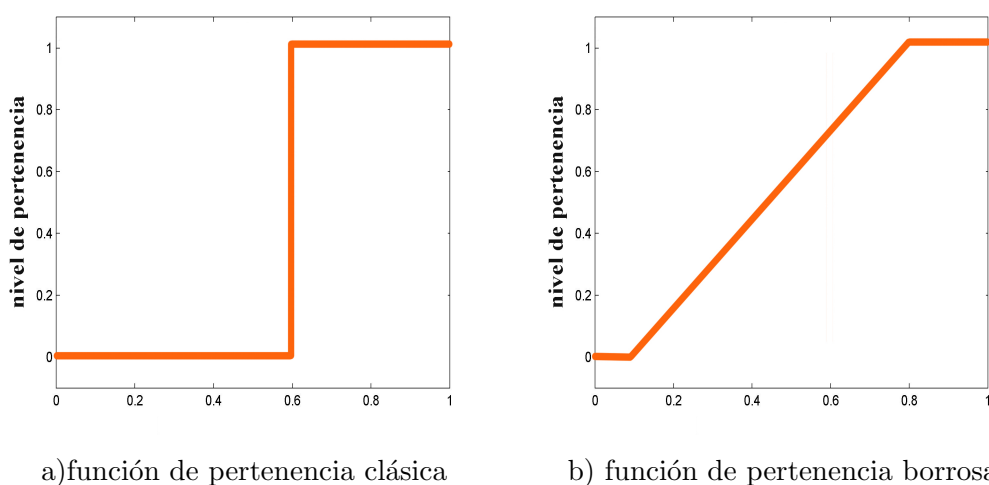


Figura 6.24: Funciones de pertenencia clásica y borrosa. En la teoría clásica un objeto sólo puede pertenecer o no a un conjunto, dando lugar a funciones abruptas con salida binaria. En la teoría borrosa, el objeto puede pertenecer al conjunto con grados de pertenencia comprendidos en el intervalo $[0,1]$, donde el valor asignado indica el grado de compatibilidad del objeto con el concepto representado por el conjunto

El hecho de que un objeto pueda pertenecer a un conjunto dentro de un intervalo de confianza permite definir conceptos vagos o imprecisos de manera natural, algo complejo con la lógica clásica. Por ejemplo, el concepto “fin de semana” en lógica borrosa permite decir que “el 30 % del viernes es fin de semana”, mientras que en lógica clásica el viernes debe considerarse como parte completa del fin de semana o como no perteneciente al fin de semana, a pesar de que eso no se ajuste bien a la realidad. La lógica borrosa es una herramienta potente que permite implementar adecuadamente mecanismos de razonamiento lingüístico.

La teoría básica para el diseño de Controladores Borrosos presentada en (Zadeh, 1973), y su primera aplicación para regular una máquina de vapor (Mamdani y Assilian,

6.3. Controlador borroso multivariable para el ajuste de tratamientos

1975), marcaron un hito en el área de control, al presentar un control que funcionaba y que había sido desarrollado sin necesidad de tener un modelo analítico y preciso del sistema, sino utilizando el conocimiento experto.

Desde el momento de su aparición, la aplicación de controladores borrosos ha seguido avanzando, siendo cada vez más popular debido en gran medida a su capacidad para plasmar la experiencia humana de control, clasificación o toma de decisión (Albertos y Sala, 2004). En definitiva, la mayoría de los controladores borrosos están basados en el trabajo de Mamdani y Assilian (1975), donde se sustituye el conocimiento del modelo analítico del sistema a controlar por el conocimiento experto de control, expresado como un conjunto de reglas de control descritas en lenguaje natural y que operan sobre términos lingüísticos (todo ello descrito mediante conjuntos borrosos).

El modelo de control borroso se formula mediante un conjunto de reglas del tipo **SI-ENTONCES**. Los *antecedentes* de cada regla contienen una descripción del estado del sistema y el *consecuente* la acción de control apropiada. Tanto los antecedentes como los consecuentes se definen sobre conjuntos borrosos de entrada y salida.

El proceso de inferencia borroso consiste en aplicar en cada momento la regla cuyo antecedente se corresponda al estado del sistema, dando lugar a la actuación apropiada. Más concretamente, dado que todos los antecedentes son borrosos, el sistema de inferencia razonará siempre sobre todas las reglas a la vez, aplicando cada una con mayor o menor relevancia en función del peso de sus antecedentes y combinando sus consecuentes. Las operaciones básicas entre conjuntos borrosos (unión, intersección, complemento) usadas tanto para la combinación de antecedentes, como de reglas y consecuentes se definen en Zadeh (1965), y pueden verse en la figura 6.25. La intersección entre dos conjuntos se establece como el mínimo de sus valores, la unión como el máximo, mientras que el complemento se define como el opuesto ($1 - \text{valor}$).

Conjuntos borrosos de entrada y salida

En la figura 6.23 se muestran las entradas y salidas del controlador. Todas las entradas toman un valor continuo dentro de un rango específico, que varía entre una entrada y otra debido a su distinta naturaleza. Dicho valor se transforma en un conjunto borroso para su posterior uso como antecedente en las reglas de inferencia del




Figura 6.25: Operaciones básicas entre conjuntos borrosos

6.3. Controlador borroso multivariable para el ajuste de tratamientos


controlador (etapa conocida como *fuzzyfication*). Para llevar esto a cabo, se definen las funciones de pertenencia mostradas en la figura 6.26. En todas ellas se ha preferido la forma trapezoidal de los conjuntos a otras representaciones por su sencillez y su mayor rapidez de cómputo.

La figura 6.26(a) muestra los conjuntos borrosos perteneciente a la variable de entrada IC. El rango de valores, al tratarse de un porcentaje, va desde 0 a 100. La caracterización de IC se ha realizado en cuatro conjuntos (nada, poco, medio y mucho). El valor de los rangos ha sido escogido con la ayuda de un grupo de expertos en *malherbología*. La variable de entrada EC, figura 6.26(b) se ha representado de forma similar con 3 conjuntos (bajo, medio y alto).


La velocidad, figura 6.26(c) varía entre 0 y 8 Km/h , que son las velocidades habituales del tractor en tareas de laboreo. El caudal, figura 6.26(d) ha sido normalizado, considerando como máximo los 31 l/min de los que es capaz la barra de tratamiento HARDI NK. La caracterización de la velocidad se ha hecho en cinco conjuntos y la del caudal en tres conjuntos, para hacer más flexible la actuación sobre la velocidad, como se explicará más adelante.

Del mismo modo, las salidas son conjuntos borrosos definidos por las funciones de pertenencia mostradas en la figura 6.27. Aquí la velocidad y el caudal no son valores absolutos, sino el valor de incremento o decremento que el controlador determina que hay que realizar sobre la velocidad y caudal de entrada. Por ello, la velocidad oscila entre $[-5, 5]$ (5 Km/h más rápido o más despacio), y el caudal entre $[-1, 1]$ (reducirlo al mínimo o subirlo al máximo). Si los valores de incremento o decremento sobre el valor actual dan lugar a valores fuera de rango (como por ejemplo velocidades negativas) simplemente se reescala la actuación al máximo o mínimo permitido. Igual que ocurría para las entradas al controlador, la velocidad está caracterizada en cinco conjuntos mientras que el caudal sólo en tres.


La otra salida (sección) tiene dos posibles valores (abrir o cerrar sección), por lo que no es necesario ningún conjunto borroso para tenerla en cuenta.




(a) Índice de cobertura



(b) Estado de crecimiento



(c) Velocidad



(d) Caudal

Figura 6.26: Funciones de pertenencia de los conjuntos borrosos de entrada

6.3. Controlador borroso multivariable para el ajuste de tratamientos




Figura 6.27: Funciones de pertenencia de los conjuntos borrosos de salida

Reglas Borrosas

Una vez convertidas las entradas a conjuntos borrosos, se aplican las reglas de inferencia para hallar las salidas. Lo más relevante de este conocimiento se resume en la tabla 6.2. El diseño de las reglas, como ya se comentó, lo ha realizado un experto. Las filas representan el valor de entrada (conjunto borroso) de IC, mientras que las columnas representan el valor de entrada de EC. El valor de las casillas representa la cantidad de herbicida a aplicar, donde 0 significa no aplicar tratamiento, 1 aplicar la dosis máxima, $1/2$ aplicar media dosis y $1/4$ aplicar un cuarto de dosis. Los expertos en la materia consideran suficiente esta separación de las posibles dosis, y no recomiendan añadir mayor complejidad. En IC, los dos extremos (Nada y Mucho) son aquellos en los que siempre se aplica la dosis mínima de herbicida o la dosis máxima respectivamente, dando igual el valor que tome la variable EC. Sin embargo los dos conjuntos (Poco y Medio) dependen del EC, ya que cuando el cultivo está poco crecido la mala hierba es potencialmente más peligrosa que la misma cantidad de infestación en un cultivo bien desarrollado, siendo por tanto necesario emplear más herbicida.

Por otro lado, la actuación del controlador debe ajustar la apertura/cierre de sección así como el caudal y la velocidad para alcanzar una dosis adecuada a cada situación. El

IC/EC	Poco	Medio	Alto
Nada	0	0	0
Poco	1/2	1/2	1/4
Medio	1	1	1/2
Mucho	1	1	1

Tabla 6.2: Reglas para determinar la cantidad de herbicida a aplicar, obtenidas a partir de conocimiento experto

ajuste es sencillo, por ejemplo para alcanzar una dosis mínima (sin tratamiento) basta cerrar la sección, no dejando pasar nada de herbicida. Para el resto de valores, basta abrir la sección y combinar la velocidad con el caudal teniendo en cuenta que a mayor caudal más cantidad de tratamiento aplicado. Con la velocidad pasa lo contrario, ya que cuánto más rápido va el tractor menos tiempo pasa por encima de la mala hierba y por tanto el tratamiento pulverizado por unidad de terreno es menor. Esto se resume en la tabla 6.3.

Combinando ambas tablas se forman las reglas borrosas: se miran los valores de IC y de EC, para determinar qué dosis hay que aplicar (tabla 6.2), y con dicho valor se varía el caudal y la velocidad de entrada hasta alcanzar el valor deseado (tabla 6.3). En total, el sistema de inferencia del controlador borroso está compuesto de 52 reglas.

Como ya se ha dicho previamente, se prefiere actuar sobre la velocidad del tractor antes que sobre el caudal. Las reglas borrosas tienen esto en cuenta, de modo que siempre que sea posible, el consecuente de la regla alcanzará la dosis deseada variando la velocidad y dejando fijo el caudal. De este modo, sólo se modificará el caudal cuando la variación sobre la velocidad no baste para alcanzar la dosis deseada (por ejemplo si la velocidad es *Máxima*, el caudal *Bajo* y se desea alcanzar dosis máxima). Estas operaciones se ven favorecidas por el hecho de que la caracterización de la velocidad se ha realizado en muchos conjuntos borrosos, ofreciendo un mayor abanico de posibilidades de actuación en el consecuente de la regla.

Una vez halladas las salidas borrosas, éstas deben ser reconvertidas a valores no borrosos, mediante algún método de decodificación, conocido como *defuzzification*, ya

6.3. Controlador borroso multivariable para el ajuste de tratamientos

Velocidad	Caudal	Dosis Herbicida
Mínima	Bajo	1/2
Mínima	Medio	1
Mínima	Alto	1
Baja	Bajo	1/2
Baja	Medio	1/2
Baja	Alto	1
Media	Bajo	1/4
Media	Medio	1/2
Media	Alto	1/2
Alta	Bajo	1/4
Alta	Medio	1/4
Alta	Alto	1/2
Máxima	Bajo	1/4
Máxima	Medio	1/4
Máxima	Alto	1/4

Tabla 6.3: Ajuste de la salida actuando sobre el caudal y la velocidad, suponiendo la sección abierta

que el sistema a controlar necesita entradas analógicas. De entre los métodos de *defuzzification*, el más utilizado es el cálculo del centroide.

El centroide de un área se puede definir como su centro geométrico, de modo similar al centro de masas de un cuerpo. Las coordenadas (Cx, Cy) del centroide de un área A se calculan como la media de las coordenadas (x, y) de todos los puntos que forman el área:

$$(Cx, Cy) = \left(\frac{\int_A x dA}{A}, \frac{\int_A y dA}{A} \right) \quad (6.1)$$

En el problema planteado, se tiene que calcular el centroide de un conjunto de áreas distintas $[A_1, A_N]$. En este caso, primero se calcula el centroide de cada una de ellas por separado $[(Cx_1, Cy_1), (Cx_N, Cy_N)]$ siguiendo la ecuación 6.1 y posteriormente se calcula el centroide global como la media aritmética de todos los centroides:

$$(Cx, Cy) = \left(\frac{\sum_{i=1}^N A_i Cx_i}{\sum_{i=1}^N A_i}, \frac{\sum_{i=1}^N A_i Cy_i}{\sum_{i=1}^N A_i} \right) \quad (6.2)$$

El cálculo de centroide de una salida borrosa asigna como salida final, analógica, el valor asociado con el centro de masas de los conjuntos borrosos entre los que se sitúa la salida, figura 6.28. Nótese que en este caso sólo es relevante el valor del centroide en el eje x, Cx .

6.3.3. Resultados

El controlador ha sido implementado en el entorno de desarrollo de Matlab. Su funcionamiento se ha probado primero en simulaciones, para estudiar el comportamiento ante diversas situaciones y posteriormente se ha efectuado la unión entre el controlador borroso y el sistema de percepción sobre muestreos fotográficos, dando lugar al sistema completo de tratamiento selectivo, capaz de decidir en cada momento la dosis óptima a aplicar en función de los datos recogidos y procesados en la etapa de percepción.




Figura 6.28: Decodificación de la salida a valores no borrosos mediante cálculo de la coordenada del centroide en el eje x

Resultados en simulación

Para las simulaciones, se han generado mapas sintéticos para un campo de 200 metros de largo por 80 de ancho (4 idas y vueltas del tractor), con una separación entre líneas de cultivo de 37cm. Los mapas de *Índice de Cobertura* y de *Estado de Crecimiento* se generan aleatoriamente (aunque siguiendo unas restricciones que aseguran que representan situaciones reales). Todos estos valores son ajustables por parámetro y se pueden cambiar entre ejecuciones, permitiendo simular un amplio abanico de situaciones.

La figura 6.29 muestra un ejemplo de ejecución. Las figuras 6.29(a) y 6.29(b) muestran los mapas de *Índice de Cobertura* y de *Estado de Crecimiento* generados. Nótese que en el mapa de *Índice de Cobertura* aparecen rodales (como en los campos reales), y que el mapa de *Estado de Crecimiento* muestra líneas con una distribución semejante a las líneas de cultivo. La figura 6.29(c) muestra la salida del controlador en forma de mapa de aplicación de herbicida.

Por otra parte, las figuras 6.30(a) y 6.30(b) muestran los cambios sufridos por los variadores de velocidad y caudal a lo largo del tiempo. Analizando en detalle estas figuras, se comprueba que los cambios efectuados sobre la velocidad y el caudal son

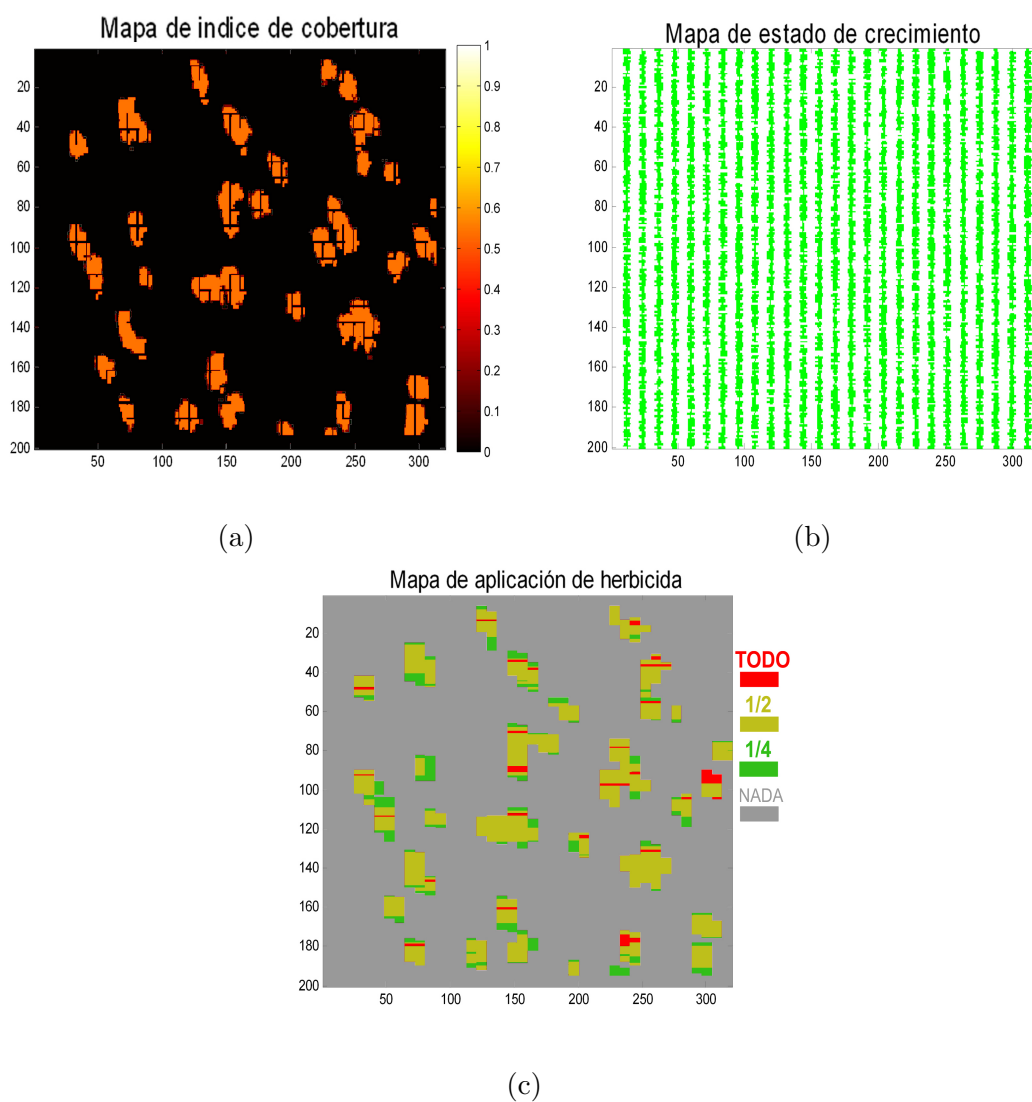


Figura 6.29: Simulación del resultado del controlador borroso. a) Mapa de Índice de Cobertura generado aleatoriamente, b) Mapa Estado de Crecimiento generado aleatoriamente y c) Mapa de tratamiento, construido a partir de la salida del controlador borroso implementado

6.3. Controlador borroso multivariable para el ajuste de tratamientos

pocos y que, como se quería, la actuación es mayor sobre la velocidad que sobre el caudal (un 10.1 % de veces se actúa sobre la velocidad frente a un 1.1 % de actuación sobre el caudal). También se ve que los cambios sobre el caudal son bastante bruscos, debido a que las actuaciones sobre el mismo se realizan cuando no hay otra solución más que un cambio drástico. En cualquier caso el comportamiento del controlador es flexible a cambios y se pueden introducir otros comportamientos propuestos por expertos.

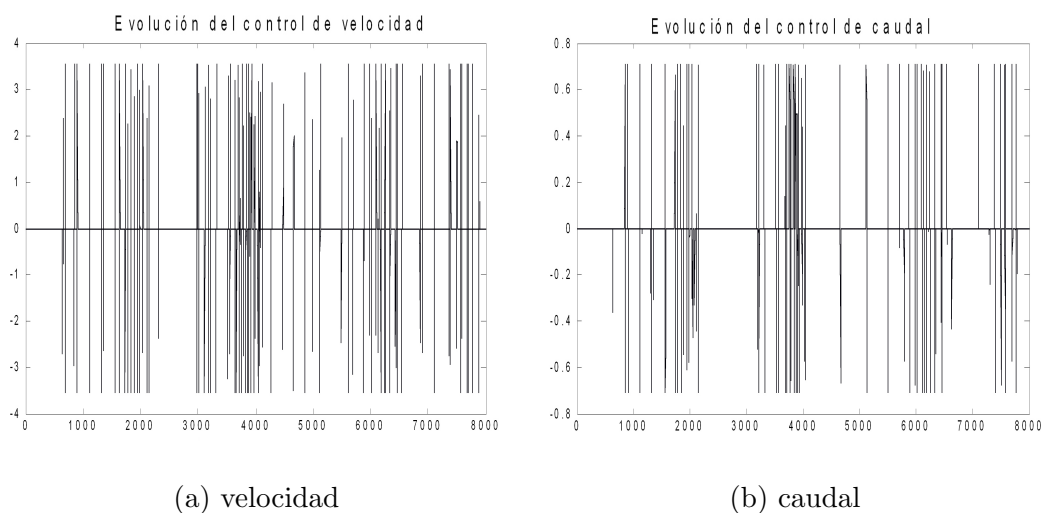


Figura 6.30: Evolución de la acción de control sobre la velocidad y el caudal

Finalmente, se ha efectuado un breve estudio sobre el comportamiento del controlador en 20 situaciones distintas generadas aleatoriamente. Dicho estudio muestra que el controlador opta, la mayor parte de las veces (56,8 %) por no aplicar dosis máxima, lo cual se traduce, al compararse con las prácticas habituales de aplicación de herbicida (dosis fija en todo el campo), en que el sistema produce mapas de dosificación en los que de media se emplea 9,5 veces menos herbicida que aplicando dosis máxima y 4,5 veces menos que con media dosis. Aunque éstas son cantidades que suelen disminuir al trasladarse a la realidad, debido a todas aquellas variables que no aparecen en las simulaciones, como pueden ser el viento o la resistencia de las plantas, no dejan de ser unos resultados satisfactorios.

Integración de los sistemas de percepción y actuación

Una vez el controlador diseñado, desarrollado y probado en simulaciones, se ha llevado a cabo la unión entre el controlador y la etapa de percepción.

Los campos de pruebas usados son dos de los campos de maíz de la finca de La Poveda, al sudeste de Madrid, ambos de tamaños aproximados de $160m$ de largo por $80m$ de ancho. En ellos se han realizado muestreos discretos durante los últimos tres años, usando el primer campo en el 2007 y el segundo en 2008 y 2009. En los muestreos se han recogido tanto fotografías, como muestras de tierra para su posterior análisis en laboratorio, estableciendo los valores de biomasa asociados con cada fotografía. En cada uno, se han tomado 160 puntos de muestreo ajustados a una malla de 20×8 puntos, figura 6.31.




Figura 6.31: Resolución de los muestreos discretos llevados a cabo

Cada una de las 160 fotografías fue procesada usando la plataforma de imágenes presentada en el capítulo 4, ajustando los métodos y valor de los parámetros mediante el CBR, de forma totalmente automática, dando lugar a valores de infestación y cultivo asociados con cada una de las imágenes. A partir de estos valores, usando el método de interpolación implementado en la plataforma (kriging), se han construido los mapas de IC y EC, ambos de 160×80 puntos y resolución de $1m \times 1m (1m^2)$ por punto.

Una vez construidos los mapas, éstos se pasaron al controlador, generándose en

6.3. Controlador borroso multivariable para el ajuste de tratamientos

cada caso un mapa de tratamiento asociado. Las figuras 6.32, 6.33 y 6.34 muestran los resultados partiendo de los muestreos de los años 2007, 2008 y 2009 respectivamente.

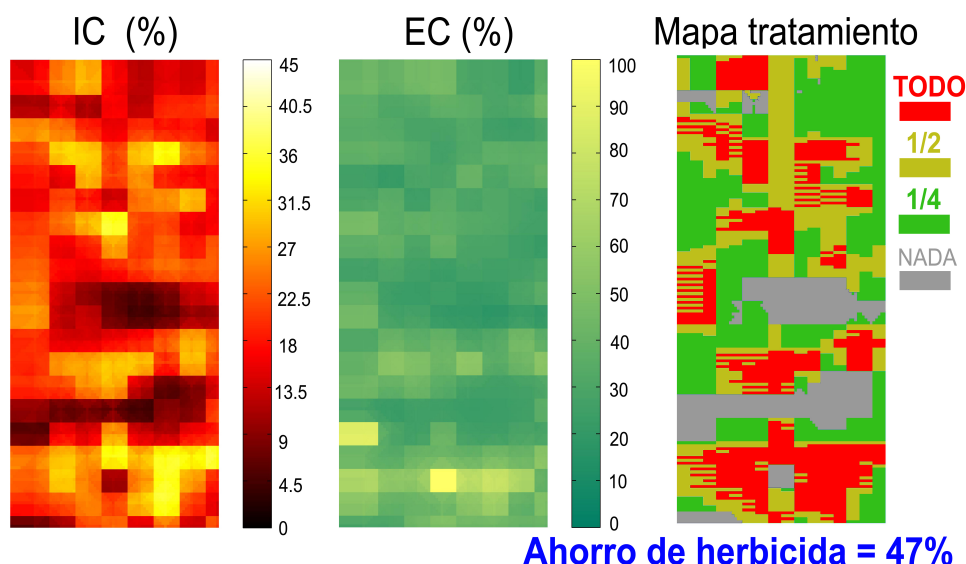


Figura 6.32: Resultados del controlador borroso sobre el muestreo del año 2007

Lo primero que se comprueba al observar los resultados es la tremenda variabilidad presentada en los valores de índice de cobertura y estado de crecimiento según el campo y el año. El primer campo, usado en el 2007, se encontraba en una situación límite de infestación y de desarrollo del cultivo debido a los constantes retrasos sobre la fecha de aplicación de herbicida sufridos a lo largo de los años, causados por la infinidad de pruebas realizadas tanto por parte de miembros del IAI-CSIC como del CCMA-CSIC. El campo presentaba valores medios de cobertura de malas hierbas del 20 % con picos de hasta 45 %, y valores medios de densidad de cultivo cercanos al 50 %, valores muy superiores a los encontrados en un campo normal en fechas de tratamiento. Por tanto, en los años siguientes (2008 y 2009), se decidió dejar el primer campo en barbecho y utilizar el segundo campo, que mostró valores medios de IC del 6 % con picos cercanos al 25 %, y una media de EC del 21 %, valores mucho más representativos de la situación habitual en fecha de tratamientos.

Los mapas de tratamiento generados por el controlador son, como cabía esperar, consecuencia directa de los valores observados y las reglas de aplicación de la tabla

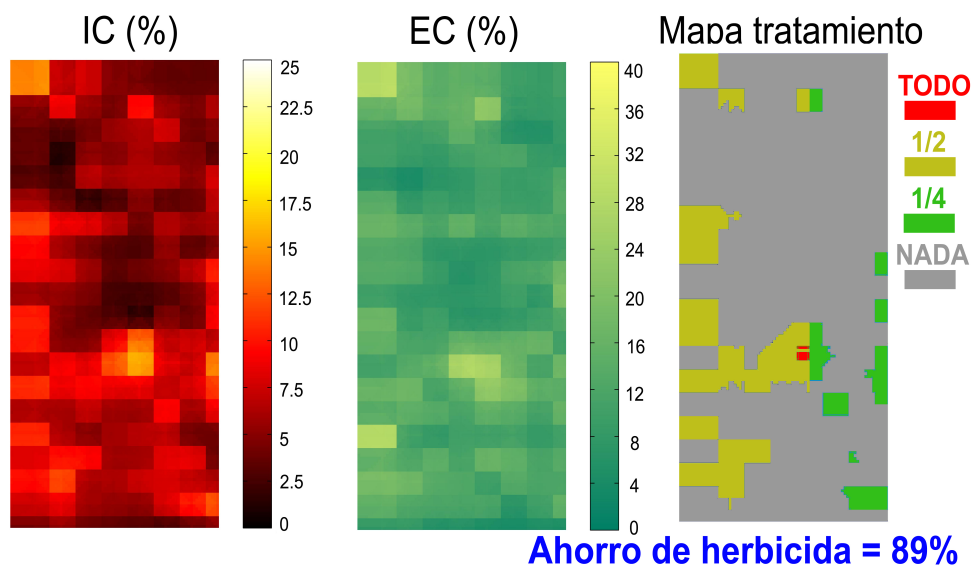


Figura 6.33: Resultados del controlador borroso sobre el muestreo del año 2008

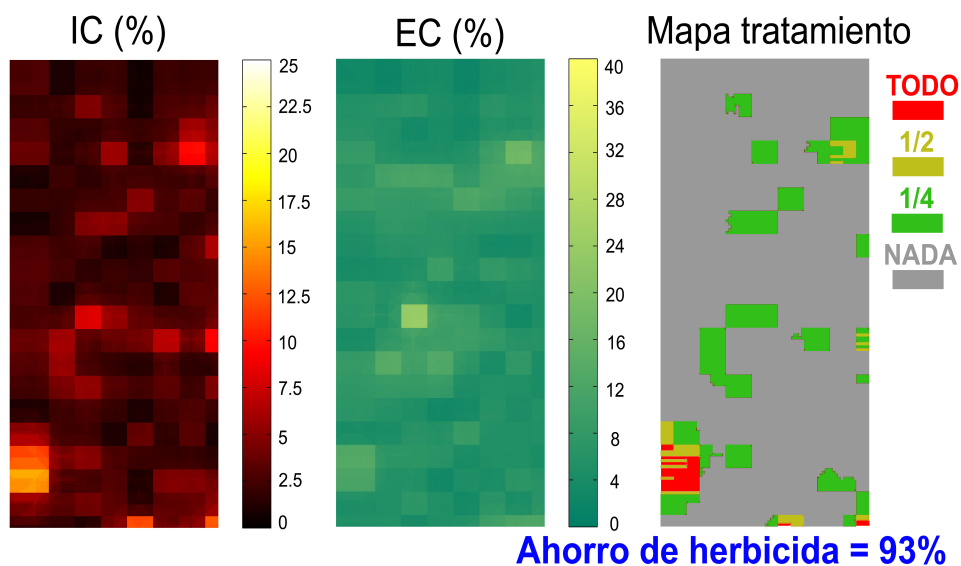


Figura 6.34: Resultados del controlador borroso sobre el muestreo del año 2009

6.3. Controlador borroso multivariable para el ajuste de tratamientos

6.2. Esta aplicación selectiva se traduce en ahorros de herbicida del 47 %, 89 % y 93 % respectivamente, evidenciando el claro beneficio de la aplicación de técnicas de AP.

Observando en detalle los mapas de tratamiento resultado de cada año, en el 2007, se aplica dosis completa el 26 % de las veces, frente a un 36 % de media dosis, 22 % de un cuarto y el 16 % se decide no aplicar nada de herbicida. La alta variabilidad espacial encontrada, hace que se actúe sobre la velocidad el 67 % de las veces y un 5 % sobre el caudal.

En el 2008, debido a la poca cantidad de infestación presente, se aplica dosis completa sólo el 1,6 % de las veces, media dosis el 15 %, un cuarto el 5 %, y el 78 % de las veces no se aplica nada de herbicida. Debido a que la mayor parte del tiempo se escoge no aplicar herbicida, los pocos casos en los cuales se decide hacerlo se traducen en la necesidad de un cambio de dosis drástico, siendo en este caso más frecuente la actuación sobre el caudal (15 %) que sobre la velocidad (2 %).

En el 2009, se determina aplicar dosis completa el 1.4 % de las veces, el 1.8 % media dosis, el 13.2 % un cuarto y el 83.6 % no aplicar nada de herbicida. La actuación en este caso es mínima, en concreto el 5.1 % de las veces se actúa sobre la velocidad y el 1.3 % sobre el caudal.

En los años 2008 y 2009, la cantidad aplicada de herbicida es muy similar, a pesar de que los mapas de IC muestran diferencias importantes, habiendo mucha más infestación en el 2008 que en el 2009 (12 % y 4 % de media respectivamente). Esto se debe a que en el 2008 el cultivo muestra un estado de desarrollo más avanzado que en el 2009 (valores medios de EC del 17 % y 11 % respectivamente), y por lo tanto el riesgo que representan las malas hierbas es menor.

Si se analizan los valores medios de cobertura de malas hierbas a lo largo de estos últimos 3 años, figura 6.35, se comprueba que el 93 % del tiempo la densidad de infestación se sitúa por debajo del 40 %, y por debajo del 40 % un 72 % de las veces, lo que indica el potencial beneficio de la aplicación de tratamientos selectivos, y evidencia el claro éxito que se puede obtener al aplicar técnicas de Agricultura de Precisión en contraste con las técnicas clásicas, y cómo las tecnologías propias de la automática y la informática pueden resultar de gran utilidad en el ámbito agrícola como también concluyen otros autores (Martínez et al., 2005).

Índice de cobertura medio




Figura 6.35: Valores medios de cobertura de malas hierbas obtenidos en los muestreos de los años 2007, 2008 y 2009

Una vez probadas todas las partes por separado (control sobre la barra desde un ordenador y generación de mapas de tratamiento a partir de los datos recogidos en la etapa de percepción), se ha llevado a cabo la integración de ambos sistemas, simulando en el laboratorio la aplicación selectiva de tratamientos.

Para ello, se realizó un segundo programa capaz de leer las coordenadas GPS suministradas por un receptor y de situarlas sobre el mapa de tratamiento. El receptor GPS que se está utilizando (Hemisphere R220) dispone de corrección diferencial y proporciona la localización a través de un puerto serie (RS232) o USB y mediante una trama GGA (codificación NMEA), ver figura 6.36.

El programa desarrollado sitúa las 20 posiciones por segundo facilitadas por el GPS sobre el mapa de tratamiento, y envía las órdenes adecuadas a la DAQ para controlar, a través del circuito desarrollado, el equipo de tratamiento en función de lo indicado por el mapa de tratamiento.

El programa desarrollado permite cargar cualquier mapa de tratamiento generado por el controlador borroso, figura 6.37(a). Luego, una vez en el campo, sitúa las 20

6.3. Controlador borroso multivariable para el ajuste de tratamientos


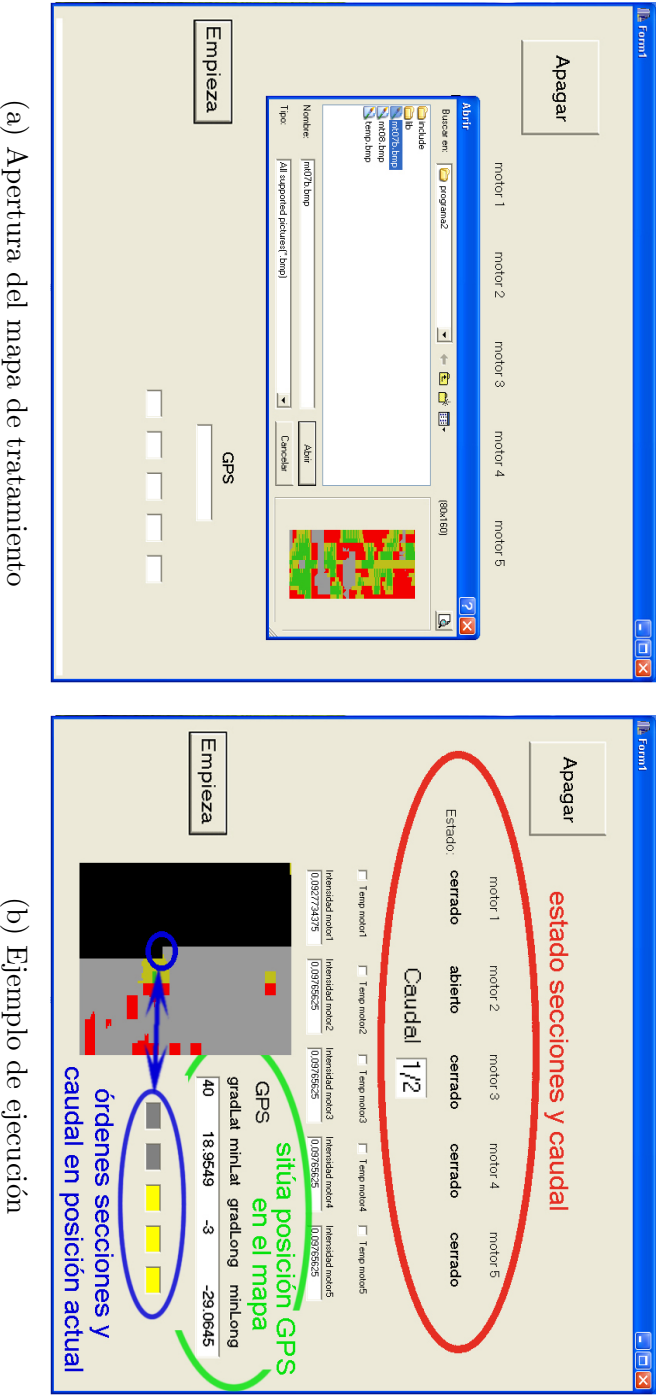


Figura 6.36: Receptor GPS Hemisphere R220

posiciones por segundo facilitadas por el GPS sobre el mapa de tratamiento, y controla el equipo de tratamiento (a través de la DAQ y el circuito desarrollado) de acuerdo a lo indicado por el mapa en la posición actual. La GUI del programa muestra en todo momento la posición actual sobre el mapa, así como las últimas órdenes enviadas a la DAQ (caudal y secciones), y el estado actual del equipo de tratamiento, figura 6.37(b).

El funcionamiento de este programa se ha comprobado en simulaciones en el laboratorio, llevando, a falta de validaciones en el campo real durante la próxima campaña, a un tratamiento selectivo de malas hierbas totalmente automático, preciso y barato.



Parte III

Conclusiones y trabajo futuro

Capítulo 7

Conclusiones y líneas de investigación futuras

La ignorancia afirma o niega
rotundamente; la ciencia duda
Voltaire

Uno de los puntos centrales de la AP es el tratamiento selectivo de malas hierbas en cultivos. Un tratamiento preciso y selectivo requiere, primero una localización exacta de las malas hierbas existentes en el cultivo y posteriormente su tratamiento acorde al riesgo que representan. Este proceso requiere la implementación de métodos automáticos, tanto de percepción (detección y localización de malas hierbas) como de actuación (aplicación de tratamientos).

En esta tesis se han propuesto tanto métodos automáticos para la etapa de percepción, como los mecanismos de automatización y control sobre la barra de tratamientos de herbicida, creando todas las herramientas necesarias para una aplicación selectiva de tratamientos automática.

Es importante destacar además, que todos los métodos propuestos han sido probados en un conjunto amplio de situaciones y en condiciones reales de trabajo, habiéndose efectuado pruebas a lo largo de los últimos cuatro años durante distintos días y en distintos campos, para asegurar una representación real de la enorme variabilidad encontrada en el campo (condiciones cambiantes de iluminación y humedad, distintos estados de crecimiento de la capa vegetal, presencia de rodales, etc.) a la que tiene que enfrentarse cualquier sistema de AP.

Más aún, todo el equipo usado para realizar este trabajo (electrónica, cámaras, ordenadores, tractor y barra de tratamientos) es convencional y lo más barato posible, buscando que la transferencia de todo lo desarrollado sea económicamente viable.

7.1. Conclusiones más relevantes

7.1.1. Percepción

El desarrollo de métodos de VA para la localización precisa de malas hierbas en una imagen es un campo de trabajo abierto y de gran importancia en AP. El problema no tiene una solución trivial, pues las condiciones cambiantes de iluminación, humedad o estados de crecimiento de la capa vegetal así como la similitud entre las malas hierbas y el cultivo hacen que la detección sea una tarea compleja.

Los métodos de procesamiento de imágenes naturales propuestos en el capítulo 4 de esta tesis para discriminar entre cultivo, malas hierbas y el resto han producido resultados satisfactorios, siendo muy robustos ante la inmensa variedad de situaciones encontradas en el campo. Se han alcanzado índices de correlación con valores reales (biomasa) de hasta un 97 % en los mejores casos y 89,4 % de media, sobre un conjunto de 136 imágenes de cereal de invierno pertenecientes a varios años.

Los buenos resultados se han logrado gracias a la división del procesamiento en varias etapas, para cada una de las cuales se han diseñado distintos métodos, con la finalidad de ajustar al máximo el procesamiento a cada una de las situaciones encontradas. Más aún, todos los métodos funcionan mediante el ajuste de una serie de parámetros de entrada, que permiten modificar y flexibilizar el procesamiento.

7.1. Conclusiones más relevantes

Debido a la gran especialización y dificultad de la tarea, tanto las etapas del procesamiento como los distintos métodos de VA desarrollados tienen una alta complejidad, siendo difícil ajustar por prueba y error el valor de los parámetros de cada método. Para el ajuste de los parámetros se han utilizado algoritmos genéticos (genético estándar y NSGA-II). El ajuste se ha efectuado sobre dos conjuntos de imágenes con diferentes condiciones de iluminación, (71 imágenes de días nublados y 65 de días soleados), pertenecientes a distintos campos de cereal de invierno y tomadas en distintos años, asegurando por lo tanto una amplia representación de condiciones de trabajo. Los resultados se han comparado con la biomasa tomada simultáneamente y en los mismos puntos que las imágenes, utilizada como patrón para evaluar el funcionamiento de los métodos desarrollados.

Los métodos han sido posteriormente incluidos en una plataforma de procesamiento de imágenes desarrollada en C++ que permite todo tipo de operaciones sobre las imágenes naturales, ya sea su apertura y visualización como su procesamiento manual o automático. Dicha plataforma proporciona además otras funciones como por ejemplo el almacenamiento de resultados junto con el procesamiento usado, la visualización de los resultados parciales obtenidos en cada etapa de análisis de la imagen o la construcción de los mapas de infestación y cultivo. Toda la plataforma ha sido diseñada bajo una GUI intuitiva, pensada para ser usada por cualquier tipo de usuario, experimentado o no en el manejo de aplicaciones informáticas, proporcionando una herramienta sencilla para el uso de los métodos.

Por otra parte, la utilización de la plataforma con distintas imágenes confirma que los mejores resultados se obtienen en cada caso utilizando métodos distintos y que el funcionamiento de cada método depende de las características de las imágenes tratadas, lo que condujo al desarrollo de un sistema basado en técnicas de Razonamiento Basado en Casos, incluido en la plataforma y que permite seleccionar automáticamente la combinación de métodos y parámetros que mejor se ajustan a una imagen, en función de características de la imagen como iluminación, errores de sembrado, etc. Usando el CBR y ampliando más el conjunto de imágenes de prueba (hasta 182, tanto de cereal como de maíz y sin dividir las según las condiciones de iluminación) se mejoró aún más el procesamiento, alcanzando medias de 82,2 % de correlación con la biomasa sobre el nuevo conjunto (sobre el cual los métodos sin CBR alcanzaban un 61 % de correlación, teniendo en cuenta que ahora las imágenes de entrada corresponden a dos tipos de cul-

tivo). Más aún, el sistema desarrollado mejora la estimación de expertos malherbólogos, que obtuvieron un 57,8 % de correlación.

Dado que este trabajo forma parte de un proyecto de investigación donde uno de los objetivos principales es el desarrollo de un sistema de percepción en tiempo real acoplado a un tractor, se pasó a aplicar los conocimientos adquiridos sobre muestreos fotográficos para el desarrollo de métodos de procesamiento en tiempo real. La detección de malas hierbas en tiempo real presenta muchas dificultades, dadas las tremendas limitaciones en tiempo de cómputo (25 frames por segundo), y al hecho de que las imágenes se toman directamente desde el tractor, causando imágenes borrosas o desplazamientos.

Los métodos de detección de malas hierbas en tiempo real propuestos para el maíz han sido probados sobre más de 12h de vídeos tomados a lo largo de cuatro años en distintos campos. A pesar de no disponer, como en el caso de las imágenes pertenecientes a muestreos discretos, de una medida de comparación con los valores reales, visualmente el procesamiento ha demostrado alcanzar una correcta discriminación entre malas hierbas, cultivo y suelo ante una gran variedad de situaciones.

El método propuesto separa el procesamiento en dos partes, una que trabaja a 25 fps (**PT**) y la otra sin restricciones temporales (**PPF**). Ambas se ejecutan en paralelo de modo que **PPF** corrige los errores cometidos por **PT** debido a su exploración insuficiente de la imagen. Otra de las claves del buen funcionamiento del sistema propuesto es su segmentación adaptable, que permite al procesamiento ser altamente robusto a cambios de iluminación repentinos, comunes en exteriores.

En caña de azúcar, la problemática es muy distinta de la encontrada en cereal o maíz, ya que las malas hierbas crecen en las líneas de cultivo y no junto a ellas, lo que obliga a efectuar la discriminación por forma, color, tamaño o textura, y no por posición. El procesamiento propuesto es capaz de detectar el 100 % de las malas hierbas discriminando éstas por diferencias espectrales (presentan menores intensidades en el azul), siempre y cuando el estado de crecimiento de éstas sea avanzado.

7.1.2. Actuación

Para lograr una aplicación selectiva de tratamientos, es imprescindible tener control sobre el equipo de aplicación de herbicida acoplado al tractor, generando dosis variables en respuesta a la salida del sistema de percepción.

Se ha presentado la automatización de una barra de tratamientos multisección, que permite la monitorización y control desde un ordenador. La caja de control manual incluida en la barra se ha sustituido por un circuito electrónico de control diseñado a medida, capaz de recoger en cada momento el estado de la barra (estado de las secciones, caudal, sobrecalentamiento de los motores) y controlar todas sus funciones, actuando tanto sobre la apertura y cierre de cada sección como sobre el caudal de tratamiento.

El circuito puede ser controlado desde un ordenador a través de una tarjeta de adquisición de datos y un programa informático con una GUI que simula las funcionalidades de la caja de control manual originalmente incluida en la barra. Con la GUI implementada se ha podido comprobar el funcionamiento de cada parte del circuito, abriendo y cerrando distintas secciones de la barra en cada instante, y controlando también el caudal aplicado desde el ordenador.

Posteriormente, se ha desarrollado un controlador borroso multivariable que usa la salida del sistema de percepción para decidir la dosis óptima de tratamiento a aplicar en cada momento y actuar en consecuencia sobre la barra de tratamientos. El sistema de inferencia del controlador, basado en lógica borrosa, ha permitido incluir de forma sencilla el conocimiento experto sobre cuál es la dosis de tratamiento recomendada en cada momento, dada la información recogida en la etapa de percepción. El sistema funciona usando 4 dosis (nada, $1/4$ de dosis, $1/2$ de dosis y dosis completa) y actuando, además de sobre las secciones y caudal de la barra, sobre la velocidad del tractor. La velocidad del tractor permite modificar la cantidad de tratamiento aplicado en cada unidad de terreno, siendo muchas veces preferible una actuación sobre la velocidad en lugar de sobre el caudal.

El controlador ha sido desarrollado en el entorno de desarrollo de Matlab. Se ha probado en simulaciones ante diversas situaciones y se ha integrado con el sistema de percepción sobre muestreos fotográficos, dando lugar a la generación de mapas de tratamiento a partir de datos obtenidos en el campo. Por último, se ha desarrollado

un programa capaz de recibir coordenadas GPS y situar el tractor sobre el mapa de tratamiento, generando las órdenes de actuación y plasmándolas sobre el equipo de tratamiento a través de la DAQ y el circuito electrónico.

Esta integración final, a falta de validaciones futuras en exteriores en la próxima campaña, da lugar a un equipo de tratamiento selectivo de malas hierbas totalmente automático, preciso y barato. Los resultados obtenidos en estas pruebas sobre muestreos discretos de malas hierbas realizados a lo largo de los últimos tres años, evidencian ahorros de herbicida medios del 76 %, con picos de 93 %, mostrando claramente los beneficios obtenidos por la aplicación de técnicas de AP como las propuestas y desarrolladas en esta tesis.

7.2. Principales aportaciones y divulgación

- Procesamiento de imágenes naturales para la estimación de las densidades de malas hierbas, cultivo y suelo en campos de maíz y cereal, obteniendo correlaciones estadísticas de hasta 97 % con valores reales, ante una gran variedad de situaciones y condiciones de trabajo. Los métodos y los resultados del ajuste mediante el algoritmo genético han sido publicados en la revista *Image and Vision Computing* (Burgos-Artizzu et al., 2009c). La plataforma de procesamiento de imágenes está pendiente de registro.
- Ajuste del procesamiento de imágenes usando la optimización multiobjetiva de NSGA-II, que ayuda a determinar los mejores compromisos entre la bondad de los resultados del procesamiento y los tiempos de ejecución. Este ajuste ha permitido establecer unas constantes asociadas a la combinación lineal ($r = -0,884$, $g = 1,262$, $b = -0,311$) para la segmentación de vegetación que han demostrado dar muy buenos resultados sobre todo tipo de imágenes de cereal, maíz e incluso caña de azúcar. El ajuste mediante algoritmos genéticos fue presentado en una conferencia internacional sobre la materia (Burgos-Artizzu et al., 2008).
- Desarrollo de un Sistema de Razonamiento Basado en Casos (CBR) que mejora el procesamiento de imágenes naturales utilizando características de la imagen a procesar y experiencias anteriores para determinar cuál es la mejor combinación de métodos y parámetros para estimar la cantidad de infestación, cultivo y suelo

7.3. Líneas de investigación futura

en la imagen. La versión inicial del sistema fue presentada a una conferencia internacional (Burgos-Artizzu y Ribeiro, 2006), donde obtuvo el premio al mejor trabajo de la sesión, y posteriormente ha sido publicado en la revista *Computers and Electronics in Agriculture* (Burgos-Artizzu et al., 2009b).

- Percepción de malas hierbas en tiempo real en maíz, robusta ante gran variedad de situaciones y usando simplemente una cámara convencional acoplada a un tractor. Estos métodos han sido presentados recientemente en una conferencia internacional sobre la materia (Burgos-Artizzu et al., 2009a).
- Percepción de malas hierbas en tiempo real en azúcar, que detecta exitosamente el 100 % de las malas hierbas en campos en estado de desarrollo avanzado. Dichos métodos están siendo usados en la actualidad por la mayor empresa azucarera Australiana, *Bundaberg Sugar*, en sus campos.
- Automatización y control sobre una barra de tratamientos, que a partir de la información recogida en la etapa de percepción, utiliza conocimiento experto para decidir la dosis óptima de tratamiento en cada unidad de terreno y actúa sobre las secciones y el caudal de la barra. Los resultados sobre muestreos realizados durante los últimos tres años, muestran un potencial ahorro medio de herbicida del 76 % con picos del 93 %. El controlador borroso ha sido publicado en la *Revista Iberoamericana de Automática e Informática Industrial* (Burgos-Artizzu et al., 2007).
- Integración de los sistemas de percepción y actuación, a través de un programa que recibe posiciones de un receptor GPS, y las sitúa sobre el mapa de tratamiento generado por el controlador borroso, permitiendo realizar una aplicación selectiva de tratamientos automática partiendo de un sencillo muestreo fotográfico.

7.3. Líneas de investigación futura y proyectos asociados

Evidentemente, aún hay margen de mejora en los métodos y herramientas propuestas, y para la siguiente campaña quedan pendientes pruebas más exhaustivas del sistema completo en el campo. Además, existen muchas líneas de investigación paralelas abiertas dentro del contexto del trabajo de investigación asociado a esta tesis. A

continuación se indican algunas de las líneas de investigación futura más importantes relacionadas con este trabajo, y se describen brevemente alguno de los proyectos asociados.

7.3.1. Métodos de percepción en imágenes

Gracias a los buenos resultados obtenidos por los métodos ante una gran variedad de situaciones, la plataforma de procesamiento de imágenes desarrollada está lista para entrar en el último ciclo, donde será puesta a prueba por personal experto del Instituto de Ciencias Agrarias del CCMA-CSIC para validar su funcionamiento y ser finalmente registrada comercialmente.

Además, sería interesante incluir en la plataforma los algoritmos genéticos diseñados para el ajuste del procesamiento y desarrollados inicialmente en Matlab, permitiendo ajustes de parámetros sobre cualquier conjunto de imágenes, en cualquier momento, a petición del usuario.

El ajuste mediante NSGA-II, que ha demostrado un enorme potencial para el ajuste de los métodos y el estudio del procesamiento, podría ser ampliado añadiendo alguna otra función objetivo considerada relevante, como por ejemplo, la sencillez de la solución.

En cuanto al CBR, aún quedan varias posibles mejoras al sistema. La primera y más evidente es la construcción de un método de cálculo de similitud entre imágenes propio, diseñado a medida, que sea capaz de resaltar las diferencias más importantes de cara al procesamiento. Por poner un ejemplo, en los métodos actuales se calculan diferencias en valores de intensidad sobre toda la imagen, cuando realmente las variaciones en intensidades en partes de la imagen como el suelo, no son relevantes de cara al procesamiento.

Asimismo, el hecho de no usar ningún método de adaptación de las soluciones recuperadas puede influir negativamente en el rendimiento del sistema si los casos nuevos presentados empiezan a ser muy diferentes de los casos almacenados en la base de casos, hecho que puede ocurrir dada la inmensa variabilidad encontrada cada año incluso en un mismo campo. Una posible adaptación de la solución posible podría ser utilizando

7.3. Líneas de investigación futura

algún método de ajuste similar al desarrollado mediante algoritmos genéticos. En este contexto, será necesario poner especial atención en que el método de adaptación no repercuta negativamente sobre la complejidad y eficiencia del sistema.

Por último, sería interesante también disponer de alguna herramienta de mantenimiento de la base de casos que asegurase en todo momento que los casos almacenados sean lo más representativos y útiles posible, maximizando la eficiencia del sistema.

7.3.2. Métodos de percepción en tiempo real

Maíz

Los métodos para la percepción en tiempo real en cultivos de maíz no han podido ser validados mas que visualmente sobre los vídeos grabados en el campo. En un futuro cercano, se realizará la integración de los sistemas de percepción en tiempo real y actuación.

Además, los métodos desarrollados podrían ser usados para llevar a cabo un mapa continuo de malas hierbas. Para ello, es necesario asociar a cada frame una posición GPS y disponer de un método de transformación de coordenadas-vídeo a coordenadas-mundo.

Por último, en los últimos años se han desarrollado técnicas muy interesantes para reducir el tiempo de cómputo en aplicaciones de VA mediante el uso de Unidades de Procesamiento Gráfico (GPU) en lugar de las Unidades Centrales de Procesamiento (CPU) convencionales (Michel et al., 2008). La aplicación de estas técnicas permitirían tal vez efectuar un procesamiento más exhaustivo de las imágenes, permitiendo la inclusión de más técnicas al procesamiento.

Caña de azúcar

Los métodos de percepción en tiempo real sobre cultivos de caña de azúcar propuestos, funcionan exclusivamente cuando las malas hierbas se encuentran en un estado de crecimiento avanzado. A pesar de que el enorme tamaño de las fincas de explotación en Australia justifica el uso de técnicas de tratamiento selectivo incluso en condiciones

tardías de desarrollo, es evidente que sería deseable disponer de métodos capaces de discriminar entre infestación y cultivo ante cualquier situación encontrada.

En este contexto, el IAI-CSIC ha iniciado una colaboración con el NCEA con vistas a desarrollar conjuntamente dichas técnicas. Desde un punto de vista teórico, parece haber elementos suficientes como para ser capaces de lograr una correcta discriminación de malas hierbas y caña de azúcar bajo cualquier circunstancia. Los nuevos métodos de discriminación podrían efectuar discriminación mediante extracción de características (forma, tamaño, color), clasificación mediante wavelets de Gabor o usando cámaras infrarrojas, ya que en el infrarrojo cercano es donde se encuentran las diferencias más evidentes en el espectro, figura 5.17.

7.3.3. Actuación

Durante la siguiente campaña se realizarán las pruebas reales en el campo del sistema completo (percepción en imágenes + actuación), usando el programa desarrollado. Las pruebas iniciales se realizarán sobre un área pequeña del campo usando tinta en lugar de herbicida, para comprobar la eficacia del sistema antes de su aplicación real, de modo similar a las pruebas realizadas en (Lamm et al., 2006).

Para variar la velocidad del tractor, en la etapa de integración del control propuesto se podría realizar la actuación sobre el variador de velocidad a través de un motor eléctrico unido a una biela, mucho más conveniente que un actuador hidráulico.

Otra posible solución, mucho más sencilla desde un punto de vista práctico, sería mantener la velocidad fija, y variar la dosis utilizando las boquillas variables *VarioSelect* recién desarrolladas por Lechler (Lechler, 2009). Consiste en un conjunto de cuatro boquillas conectadas a una única salida de pulverización, y donde la apertura/cierre de cada una de ellas puede controlarse directamente a través de señales eléctricas, permitiendo aplicar en cada momento dosis completa, 3/4 de dosis, 1/2 de dosis o 1/4 de dosis, según cuántas boquillas se dejen abiertas, figura 7.1.

En este caso el controlador debería ser rediseñado, dejando fija la velocidad y por lo tanto simplificando las reglas de la tabla 6.3. Debido a que éste ha sido desarrollado en Matlab usando la toolbox de control borroso, todos los cambios pueden realizarse




Figura 7.1: VarioSelect

de forma rápida y sencilla.

Por último, como ya se ha mencionado en la sección 7.3.2, queda pendiente la unión entre el sistema de actuación y el sistema de percepción en tiempo real.

7.3.4. Otras líneas de investigación y proyectos asociados

Los proyectos que han financiado este trabajo han dado lugar a una serie de líneas de investigación paralelas:

Vehículo autónomo para cartografía de malas hierbas

Dentro del grupo de investigación del IAI-CSIC del cual forma parte el doctorando, se ha llevado a cabo una investigación orientada al diseño y desarrollo de un vehículo autónomo para cartografía de malas hierbas. El objetivo es disponer de un vehículo de pequeñas dimensiones ($52cm \times 42cm$), totalmente automatizado, capaz de desplazarse de

forma autónoma entremedias de las líneas de cultivo, recogiendo imágenes por todos los puntos por donde pasa, efectuando un muestreo de malas hierbas de forma totalmente automática.

El guiado autónomo del vehículo se lleva a cabo mediante la detección de la orientación y posición de las líneas de cultivo usando técnicas de procesamiento de imágenes similares (aunque algo más sencillas) a las descritas en esta tesis. Pruebas iniciales llevadas a cabo en campos reales han demostrado que el vehículo es capaz de desplazarse de forma autónoma, por lo que en un futuro cercano se dotará al vehículo de GPS y cámara digital de fotos para que sea capaz de efectuar el muestreo de malas hierbas. El procesamiento de imágenes fue presentado en Gottschalk et al. (2008) y publicado en Gottschalk et al. (2009).

Desarrollo de un Cartógrafo de Malas Hierbas basado en sensores optoelectrónicos

En estrecha colaboración con el CCMA-CSIC, se ha desarrollado un sistema de cartografía que permite la creación de mapas de distribución espacial de malas hierbas de manera automática. El sistema consta de un conjunto de sensores optoelectrónicos, una tarjeta de adquisición de la señal suministrada por los sensores, un PC portátil con pantalla especial para exteriores, y un receptor GPS. Además de realizar todo el conexionado entre los dispositivos mencionados, se ha desarrollado la aplicación software que permite almacenar en una base de datos la información georreferenciada de los puntos con presencia de malas hierbas entre líneas de cultivo. En el mes de Marzo de este año se ha realizado la solicitud de patente del sistema.

7.4. Transferencia de tecnología

El trabajo de investigación asociado a esta tesis, llevado a cabo por el doctorando durante los últimos cuatro años, ha dado lugar a una patente industrial y a un registro comercial (en curso).

7.4.1. **Patentes industriales**

- Autores(Inventores): D. Andujar, X.P. Burgos-Artizzu, A. Ribeiro, J. Dorado, C. Fernandez-Quintanilla, J.J. Anaya

Título: Sistema de detección de cobertura vegetal en tiempo real y de cartografía de malas hierbas entre líneas de cultivo (ES1641.431)

Solicitante(s): Consejo Superior de Investigaciones Científicas

Fecha de solicitud: marzo 2009

7.4.2. **Registros comerciales**

- Autores(Inventores): X.P. Burgos-Artizzu, A. Ribeiro

Título: Plataforma inteligente de procesamiento de imágenes para estimación de cobertura de malas hierbas en imágenes naturales

Solicitante(s): Consejo Superior de Investigaciones Científicas

Fecha de solicitud: pendiente.

Bibliografía

- AAMODT, A. y PLAZA, E. (1994). «Case-based reasoning: Foundational Issues, Methodological Variations, and System Approaches». *AI Communications*, **7**, pp. 39–59.
- ABRAHAM, A.; GROSAN, C. y PEDRYCZ, W. (Eds.) (2008). *Engineering Evolutionary Intelligent Systems*. Studies in Computational Intelligence, volume 82, Springer, Berlin, Germany.
- AITKENHEAD, M.J.; DALGETTY, I.A.; MULLINS, C.E.; McDONALD, A.J.S. y STRACHAN, N.J.C. (2003). «Weed and crop discrimination using image analysis and artificial intelligence methods.» *Computers and Electronics in Agriculture*, **39**, pp. 157–171.
- ALBERTOS, P. y SALA, A. (2004). «Control borroso. Una metodología integradora.» *Revista Iberoamericana de Automática e Informática Industrial*, **1(3)**, pp. 22–31.
- ANDREASEN, C.; RUDEMO, M. y SEVESTRE, S. (1997). «Assessment of weed density at an early stage by use of image processing». *Weed Research*, **37**, pp. 5–18.
- ANDREY, P. y TARROUX, P. (1994). «Unsupervised Image Segmentation Using A Distributed Genetic Algorithm». *Pattern Recognition*, **27(5)**, pp. 659–673.
- ANDUJAR, D.; RIBEIRO, A.; FERNANADEZ-QUINTANILLA, C. y DORADO, J. (2009). «Assessment of weed cover: a study of the consistency and accuracy of the human perception». En: *Libro de Resúmenes del Joint International Agriculture Conference (JIAC 2009)*, volumen 1, p. 303. Wageningen Academia Publishers. ISBN 978-90-8686-113-2.

- ARBELÁEZ, P.A. y COHEN, L.D. (2006). «A Metric Approach to Vector-Valued Image Segmentation». *International Journal of Computer Vision*, **69**, pp. 119–126.
- Argus2a (2009). «Trials for bionic eye implants». <http://news.bbc.co.uk/1/hi/sci/tech/6368089.stm>.
- ASTRAND, B. y BAERVELDT, A.J. (2002). «An Agricultural Mobile Robot with Vision-Based Perception for Mechanical Weed Control.» *Autonomous Robots*, **13**, pp. 21–35.
- BAKER, J.E. (1987). «Reducing Bias and Inefficiency in the Selection Algorithm». En: *Proceeding of the Second International Conference on Genetic Algorithms*, pp. 14–21. Lawrence Erlbaum Associates, Hillsdale, NJ, USA.
- BAKKER, T.; WOUTERS, H.; VAN ASSELT, K.; BONTSEMA, J.; TANG, L.; MULLER, J. y VAN STRATEN, G. (2008). «A vision based row detection system for sugar beet». *Computers and Electronics in Agriculture*, **60**, pp. 87–95.
- BARNARD, S.T. (1983). «Interpreting Perspective Images». *Artificial Intelligence*, **21**, pp. 435–462.
- BARRET, E.C. y CURTIS, L.F. (1992). *Introduction to Environmental Remote Sensing*. Chapman & Hall, London, UK.
- BAZI, Y.; BRUZZONE, L. y MELGANI, F. (2007). «Image Thresholding based on the EM algorithm and the generalized Gaussian distribution». *Pattern Recognition*, **40**, pp. 619–634.
- BEVILACQUA, A. (2005). «Optimizing Parameters of a Motion Detection System by Means of a Distributed Genetic Algorithm». *Image and Vision Computing*, **23**, pp. 815–829.
- BHANDARKAR, S.M. y ZHANG, H. (1999). «Image Segmentation Using Evolutionary Computation». *IEEE Transactions On Evolutionary Computation*, **3(1)**, pp. 1–21.
- BHANU, B.; LEE, S. y DAS, S. (1995). «Adaptive Image Segmentation Using Genetic and Hybrid Search Methods». *IEEE Transactions On Aerospace and Electronic Systems*, **31(4)**, pp. 1268–1291.

BIBLIOGRAFÍA

- BILLER, R.H.; HOLLSTEIN, A. y SOMMER, C. (1997). «Precision application of herbicides by use of optoelektronic sensors». En: *Proceedings 1st European Conference on Precision Agriculture*, pp. 451–458.
- BILLINGSLEY, J. y SCHOENFISCH, M. (1997). «The successful development of a vision guidance system for agriculture.» *Computers and Electronics in Agriculture*, **16**, pp. 147–163.
- BLACKSHAW, R.E.; MOLNAR, L.J.; CHEVALIER, D.F. y LINDWALL, C.W. (1998). «Factors affecting the operation of the weed-sensing detectspray system». *Weed Science*, **46**, pp. 127–131.
- BLANCO-MORENO, J.M.; CHAMORRO, L.; MASALLES, R.M.; RECASENS, J. y SANS, F.X. (2004). «Spatial distribution of *Lolium rigidum* following seed dispersal by combine harvesters.» *Weed Research*, **44**, pp. 375–387.
- BLASCO, J.; ALEIXOS, N.; ROGER, J.M.; RABATEL, G. y MOLTÓ, E. (2002). «Robotic weed control using machine vision». *Biosystems Engineering*, **83**(2), pp. 149–157.
- BOISSARD, P.; MARTIN, V. y MOISAN, S. (2008). «A cognitive vision approach to early pest detection in greenhouse crops». *Computers and Electronics in Agriculture*, **62**, pp. 81–93.
- BONGIOVANNI, R. y LOWENBERG-DEBOER, J. (2004). «Precision Agriculture and Sustainability». *Precision Agriculture*, **5**, pp. 359–387.
- BONISSONE, PIERO P. y AYUB, SAAD (1993). «Similarity measures for case-based reasoning systems». En: *IPMU 92 Advanced Methods in Artificial Intelligence*, volumen 682, pp. 159–172. Lecture Notes in Computer Science, Springer, Berlin.
- BOOKER, L.B.; GOLDBERG, D.E. y HOLLAND, J.H. (1989). «Classifier Systems and Genetic Algorithms». *Artificial Intelligence*, **40**, pp. 235–282.
- BOSCH, A.; MUÑOZ, X. y FREIXENET, J. (2007). «Segmentation and description of natural outdoor scenes». *Image and Vision Computing*, **25**, pp. 727–740.
- BOSSU, J.; GÉE, CH.; JONES, G. y TRUCHETET, F. (2009). «Wavelet transform to discriminate between crop and weed in perspective agronomic images». *Computers and Electronics in Agriculture*, **65**, pp. 133–143.

- BROWN, R.B. y STECKLER, J.P.G.A. (1995). «Prescription maps for spatially variable herbicide application in non-till corn». *Transactions of the American Society of Agricultural Engineers*, **38**, pp. 1659–1666.
- BUCKLES, B. P. y PETRY, F.E. (1992). *Genetic Algorithms*. IEEE Computer Society Press, Los Alamitos, Ca, USA.
- BURGOS-ARTIZZU, X. P. y RIBEIRO, A. (2006). «Un sistema de Razonamiento Basado en Casos en el Análisis de Imágenes Naturales». En: *5ta. Conferencia Iberoamericana en Sistemas, Cibernética e Informática (CISCI 2006)*, volumen 1, pp. 140–145. Orlando, USA. ISBN 980-6560-89-2.
- BURGOS-ARTIZZU, X. P.; RIBEIRO, A. y DE SANTOS, M. (2007). «Controlador Borroso Multivariable Para el Ajuste de Tratamientos en Agricultura de Precisión». *Revista Iberoamericana de Automática e Informática Industrial*, **4(2)**, pp. 64–71.
- BURGOS-ARTIZZU, X. P.; RIBEIRO, A. y PAJARES, G. (2009a). «Precise Real-time Crop / Weed Discrimination in Widely Spaced Crop Fields». En: *2009 IEEE International Conference on Robotics and Automation*, Kobe, Japan.
- BURGOS-ARTIZZU, X. P.; RIBEIRO, A.; TELLAECHÉ, A. y PAJARES, G. (2008). «Optimisation Of Natural Images Processing Using Different Evolutionary Algorithms». En: *Proc. 2008 IEEE Congress on Evolutionary Computation*, Hong Kong. ISBN 978-1-4244-1823-7.
- BURGOS-ARTIZZU, X. P.; RIBEIRO, A.; TELLAECHÉ, A. y PAJARES, G. (2009b). «Improving weed pressure assessment using digital images from an experience-based reasoning approach». *Computer and Electronics in Agriculture*, **65(2)**, pp. 176–185.
- BURGOS-ARTIZZU, X. P.; RIBEIRO, A.; TELLAECHÉ, A.; PAJARES, G. y FERNÁNDEZ-QUINTANILLA, CÉSAR (2009c). «Analysis of Natural Images Processing for the Extraction of Agricultural Elements». *Image and Vision Computing*. [Http://dx.doi.org/10.1016/j.imavis.2009.05.009](http://dx.doi.org/10.1016/j.imavis.2009.05.009).
- BURKS, T.F.; SHEARER, S.A.; HEATH, J.R. y DONOHUE, K.D. (2005). «Evaluation of Neural Network Classifiers for Weed Species Discrimination». *Biosystems Engineering*, **91(3)**, pp. 293–304.

BIBLIOGRAFÍA

- CARDINA, J.; JOHNSON, G.A. y SPARROW, D. (1997). «The nature and consequence of weed spatial distribution». *Weed Science*, **45**, pp. 364–373.
- CE, DIRECCIÓN GENERAL DE AGRICULTURA (2003). «La Agricultura y el Medio ambiente». <http://ec.europa.eu/agriculture/publi/fact/envir/2003es.pdf>.
- CE, DIRECCIÓN GENERAL DE AGRICULTURA (2009a). «Agricultura y Alimentación». <http://ec.europa.eu/agriculture/food/indexes.htm>.
- CE, DIRECCIÓN GENERAL DE AGRICULTURA (2009b). «Agricultura y Medio ambiente». <http://ec.europa.eu/agriculture/envir/indexes.htm>.
- CHOU, J.J.; CHEN, C.P. y YEH, J.T. (2007). «Crop identification with wavelet packet analysis and weighted Bayesian distance». *Computers and Electronics in Agriculture*, **57**, pp. 88–98.
- CHRISTENSEN, S.; HEISEL, T. y PAICE, M. (1999). «Simulation of long term Alopecurus myosuroides population using three patch spraying strategies». En: *Proceedings 2nd European Conference on Precision Agriculture*, pp. 977–987.
- CHRISTENSEN, S.; HEISEL, T.; WALTER, A.M. y GRAGLIA, E. (2003). «A decision algorithm for patch spraying». *Weed Research*, **43**(4), pp. 276–284.
- CHUVIECO, E. (1996). *Fundamentos de Teledetección espacial*. Ediciones Rialp, S. A..
- CIT, CALIFORNIA INSTITUTE OF TECHNOLOGY (2007). «Camera Calibration Toolbox for Matlab». http://www.vision.caltech.edu/bouguetj/calib_doc.
- COELLO, C.; VAN VELDHUIZEN, D. y LAMONT, G. (2002). *Evolutionary Algorithms for Solving Multi-Objective Problems*. Kluwer Academic Publisher.
- CRESSIE, N.A.C. (1993). *Statistics for spatial data*. Wiley, New York.
- DAVIS, L. (1987). *Genetic Algorithms and Simulated Annealing*. Morgan Kaufman Publishers, San Mateo, Ca, USA.
- DÍAZ, B.; RIBEIRO, A.; GONZALEZ-BUENO, R.; GUINEA, D.; BARROSO, J.; RUIZ, D. y FERNÁNDEZ-QUINTANILLA, C. (2005). «Modelling Wild-Oat Density In Terms Of Soil Factors: A Machine Learning Approach». *Precision Agriculture*, **6**(2), pp. 213–228.

- DEB, K. (2001). *Multi-Objective Optimization Using Evolutionary Algorithms*. John Wiley & Sons, Inc, New York, NY.
- DEB, K.; AGARWAL, S.; PRATAP, A. y MEYARIVAN, T. (2000). «A Fast Elitist Non-Dominated Sorting Genetic Algorithm for Multi-Objective Optimization: NSGA-II». En: *Proceeding of the Parallel Solving from Nature VI Conference*, pp. 849–858. Springer.
- DEB, K.; PRATAP, A.; AGRAWAL, S. y MEYARIVAN, T. (2002). «A Fast and Elitist Multiobjective Genetic Algorithm». *IEEE Transactions on Evolutionary Computation*, **6**(2).
- DI GESÙ, V. y STAROVOITOV, V. (1999). «Distance-based functions for image comparison». *Pattern Recognition Letters*, **20**, pp. 207–214.
- DICK, D. y KROHMANN, P. (2007). «Dynamics of Weed Populations under the influence of Site-Specific Weed Control; a 10 years study». En: *Proceedings 2nd Conference on Precision Crop Protection*, .
- DIELEMAN, J.A. y MORTENSEN, D.A. (1999). «Characterizing the spatial pattern of Abutilon theophrasti seedling patches». *Weed Research*, **39**, pp. 455–467.
- DIELEMAN, J.A.; MORTENSEN, D.A.; BUHLER, D.D. y FERGUSON, R.B. (2000). «Identifying associations among site properties and weed species abundance. Hypothesis generation». *Weed Science*, **48**, pp. 576–587.
- DONALD, W. W. (1994). «Geostatistics for mapping weeds with a Canada thistle *Cirsium arvense* path as a case study». *Weed Science*, **42**, pp. 648–657.
- DUNN, M.; BILLINGSLEY, J. y BELL, D. (2006). «Field Testing of Vision Based Macadamia Yield Monitoring». *Sensor Review*, **26**(4), pp. 312–317.
- EARL, R.; WHEELER, P.N.; BLACKMORE, B.S. y GODWIN, R.J. (1996). «Precision Farming: The management of variability». *Landwards*, **51**(4), pp. 18–23.
- EHH, ENVIRONMENT & HUMAN HEALTH (2003). «Risks from Lawn Care Pesticides».
- FAO, ONU (2007). <http://faostat.fao.org/>.

BIBLIOGRAFÍA

- FELTON, W.L. y NASH, P.G. (1998). «Role of reflectance techniques in precision weed management». En: *Precision weed management in crops and pastures*, pp. 453–463. Ed. Por R.W. Medd y J.E. Pratley. CRC for Weed Management Systems.
- FINLAYSON, G.D.; HORDLEY, S.D. y DREW, M.S. (2002). «Removing Shadows from Images». En: *ECCV 2002*, .
- FONSECA, C.M. y FLEMING, P.J. (1993). «Genetic algorithms for multi-objective optimization: Formulation, discussion and generalization». En: *Proceeding of the Fifth International Conference on Genetic Algorithms*, pp. 416–423. San Mateo, Ca, USA.
- GARCÍA PÉREZ, L. (2004). *Navegación Autónoma de Robots en Agricultura: Un Modelo de Agentes*. Universidad Complutense de Madrid, Tesis Doctoral.
- GERHARDS, R. (2007). «Managing weeds with respect to their spatial and temporal heterogeneity». En: *2nd Conference on Precision Crop Protection*, .
- GERHARDS, R. y CHRISTENSEN, S. (2003). «Real-time weed detection, decision making and patch spraying in maize, sugarbeet, winter wheat and winter barley.» *Weed Research*, **43**, pp. 385–392.
- GERHARDS, R. y OEBEL, H. (2006). «Practical experiences with a system for site-specific weed control in arable crops using real-time image analysis and GPS-controlled patch spraying». *Weed Research*, **46**, pp. 185–193.
- GÓMEZ DE SILVA GARZA, A. y MAHER, M. L. (2000). «A process model for evolutionary design case adaptation.» En: *Proceedings of the Artificial Intelligence in Design Conference*, pp. 393–412. Kluwer Academic Publishers.
- GOEL, P. K.; PRASHER, S.O.; PATEL, R.M.; LANDRY, J. A.; BONNELL, R. B. y VIAU, A.A. (2003). «Classification of hyperspectral data by decision trees and artificial neural networks to identify weed stress and nitrogen status of corn». *Computers and Electronics in Agriculture*, **39**(2), pp. 67–93.
- GOLDBERG, D.E. (1989). *Genetic Algorithms in Search, Optimization and Machine Learning*. Addison Wesley Professional publishers, USA.

- GOLDBERG, D.E. y DEB, K. (1991). *A comparative analysis of selection schemes used in genetic algorithms*. pp. 69–93. Foundation of Genetic Algorithms, Morgan Kaufmann Publishers, Inc., San Mateo, CA, USA.
- GONZALEZ, R. C. y WOODS, R. E. (2003). *Digital Image Processing*. Prentice-Hall, second^a edición.
- GONZÁLEZ-ANDÚJAR, J. L.; MARTÍNEZ-COB, A.; LÓPEZ-GRANADOS, F. y GARCÍA-TORRES, L. (2001). «Spatial distribution and mapping *Orobanche crenata* infestation in continuous Vicia faba cropping for six years». *Weed Science*, **49**, pp. 773–779.
- GOTTSCHALK, R.; BURGOS-ARTIZZU, X. P.; RIBEIRO, A.; PAJARES, G. y SÁNCHEZ-MIRALLES, A. (2008). «Real-time Image Processing for the Guidance of a Small Agricultural Field Inspection Vehicle». En: *15th International Conference on Mechatronics and Machine Vision in Practice, (M2VIP'08)*, Auckland, New Zealand. ISBN 978-0-473-13532-4.
- GOTTSCHALK, R.; BURGOS-ARTIZZU, X. P.; RIBEIRO, A.; PAJARES, G. y SÁNCHEZ-MIRALLES, A. (2009). «Real-time Image Processing for the Guidance of a Small Agricultural Field Inspection Vehicle». *International Journal of Intelligent Systems Technologies and Applications*. In press.
- GOUDY, H.J.; BENNETT, K.A.; BROWN, R.B. y TARDIF, F.J. (2001). «Evaluation of site-specific weed management using a direct-injection sprayer». *Weed Science*, **49**, pp. 359–366.
- GRANITTO, P.M.; VERDES, P.F. y CECCATTO, H.A. (2005). «Large-scale investigation of weed seed identification by machine vision». *Computers and Electronics in Agriculture*, **47**, pp. 15–24.
- GREFENSTETTE, J.J. (1986). «Optimization of Control Parameters for Genetic Algorithms». En: *IEEE Transactions on Systems, Man, and Cybernetics*, volumen 16, pp. 122–128.
- GRIMNES, M. y AAMODT, A. (1996). «A two-layer case-based reasoning architecture for medical image understanding». En: *Proceedings of EWCBR*, pp. 164–178.
- GUTIÉRREZ-PEÑA, P.A.; LÓPEZ-GRANADOS, F.; PEÑA-BARRAGÁN, J.M.; JURADO-EXPÓSITO, M.; GÓMEZ-CASERO, M.T. y HERVÁS-MARTÍNEZ, C. (2008). «Logistic

BIBLIOGRAFÍA

- regression product-unit neural networks for mapping *Ridolfia segetum* infestations in sunflower crop using multitemporal remote sensed data». *Computers and Electronics in Agriculture*, **64**(2), pp. 293–306.
- HAGUE, T. y TILLET, N.D. (2001). «A bandpass filter-based approach to crop row location and tracking». *Mechatronics*, **11**, pp. 1–12.
- HAGUE, T.; TILLET, N.D. y WHEELER, H. (2006). «Automated crop and weed monitoring in widely spaced cereals». *Precision Agriculture*, **7**, pp. 21–32.
- HEISEL, T.; CHRISTENSEN, S. y WALTER, A.M. (1997). «Validation of weed patch spraying in spring barley-preliminary trial». En: *Proceedings 1st European Conference on Precision Agriculture*, pp. 759–768.
- HEMMING, J. y RATH, T. (2001). «Computer-vision based weed identification under field conditions using controlled lighting». *Journal of Agricultural Engineering Research*, **78**(3), pp. 233–243.
- HODGSON, J.M. (1968). «The nature, ecology, and control of Canada thistle». *Informe técnico Tech. Bull. 1386*, U.S. Department of Agriculture, Agricultural Research Service, Washington, D.C., USA.
- HOLLAND, J.H. (1975). *Adaptation in natural and artificial systems*. The University of Michigan Press, Ann Arbor, USA.
- HOMOUZ, P. (2007). «The Saving Potential of Site-Specific Weed Management in Winter Cereals». En: *Proceedings 2nd Conference on Precision Crop Protection*, .
- HORN, J.; NAFPLOITIS, N. y GOLDBERG, N.E. (1994). «A niched Pareto Genetic Algorithm for multi-objective optimization». En: *Proceedings of the First IEEE Conference on Evolutionary Computation*, pp. 82–87. Piscataway, New Jersey, USA.
- HOROWITZ, M. (1973). «Spatial growth of *Sorghum halepense*». *Weed Research*, **13**, pp. 200–208.
- HUANG, K-Y. (2007). «Application of artificial neural network for detecting *Phalaris* seedling diseases using color and texture features». *Computers and Electronics in Agriculture*, **57**, pp. 3–11.

- ILO, INTERNATIONAL LABOUR ORGANIZATION (2008). «Key Indicators of the Labour Market». <http://www.ilo.org/public/english/employment/strat/download/get08.pdf> % dateend2008.
- ISHAK, A.J.; HUSSAIN, A. y MUSTAFA, M.M. (2009). «Weed image classification using Gabor wavelet and gradient field distribution». *Computers and Electronics in Agriculture*, **66**, pp. 53–61.
- JAI, ANIL K. (1989). *Fundamentals of Digital Image Processing*. PRENTICE HALL, first^a edición.
- JIMÉNEZ, A.R.; JAIN, A.K.; CERES, R. y PONS, J.L. (1999). «Non Destructive Crop Measurements by Image Processing for Crop Growth Control». *Journal of Agricultural Engineering Research*, **61**, pp. 97–105.
- JOHNSON, C.E.; SCHAFER, R.L. y YOUNG, S.C. (1983). «Controlling agricultural machinery intelligently». En: *National Conference on Agricultural Electronics Applications*, pp. 114–119. American Society of Agricultural Engineers, St Joseph, MI, USA.
- JURADO-EXPÓSITO, M.; LÓPEZ-GRANADOS, F.; ATENCIANO, S.; GARCÍA-TORRES, L. y GONZÁLEZ-ANDÚJAR, J.L. (2003a). «Discrimination of weed seedlings, wheat (*Triticum aestivum*) stubble and sunflower (*Helianthus annuus*) by near-infrared reflectance spectroscopy (NIRS)». *Crop Protection*, **22**, pp. 1177–1180.
- JURADO-EXPÓSITO, M.; LÓPEZ-GRANADOS, F.; GARCÍA-TORRES, L.; GARCÍA-FERRER, A.; SÁNCHEZ DE LA ORDEN, M. y ATENCIANO, S. (2003b). «Multi-species weed spatial variability and site-specific management maps in cultivated sunflower». *Weed Science*, **51**, pp. 319–328.
- JURADO-EXPÓSITO, M.; LÓPEZ-GRANADOS, F.; GONZÁLEZ-ANDÚJAR, J.L. y GARCÍA-TORRES, L. (2004). «Spatial and temporal análisis od *Convolvulus arvensis* L. populations over four growing seasons». *European Journal of Agronomy*, **21**, pp. 287–296.
- KAIZU, Y. y IMOU, K. (2008). «A dual-spectral camera system for paddy rice seedling row detection». *Computers and Electronics in Agriculture*, **63**, pp. 49–56.

BIBLIOGRAFÍA

- KATO, Z.; ZERUBIA, J. y BERTHOD, M. (1999). «Unsupervised parallel image classification using Markovian models». *Pattern Recognition*, **32**, pp. 591–604.
- KEELEY, P.E. y THULLEN, R.J. (1991). «Growth and interaction of barnyardgrass *Echinochloa crus-galli* with cotton *Gossypium hirsutum*». *Weed Science*, **39**, pp. 369–375.
- KEIHNER, R. y SEUFERT, H. (2000). «Automatic guidance for agricultural vehicles in Europe». *Computers and Electronics in Agriculture*, **25**, pp. 169–194.
- KOTON, P. (1988). «Reasoning about evidence in causal explanation». En: *Proceedings of AAAI 88*. Cambridge, MA., AAAI Press/MIT Press.
- KRAMER, OLIVER (2008). *Self-Adaptive Heuristics for Evolutionary Computation*. Studies in Computational Intelligence, volume 147, Springer, Berlin, Germany.
- KROPFF, M.J.; WALLINGA, J. y LOTZ, L.A.P. (1997). «Modelling for precision weed management.» En: *Precision Agriculture: spatial and temporal variability of environmental quality*, pp. 182–204. Wiley, Chester.
- KULLBACK, S. y LEIBLER, R.A. (1951). «On information and sufficiency». *The Annals of Mathematical Statistics*, **22**, pp. 79–86.
- LACHAPPELLE, G. y HENRIKSEN, J. (1995). «GPS under cover; the effect of foliage on vehicular navigation». *GPS World*, **6(3)**, pp. 26–35.
- LAMB, D.W.; WEEDON, M.M. y REW, L.J. (1999). «Evaluating the accuracy of mapping weeds in seedling crops using airborne digital imaging: Avena spp. in seedling triticale». *Weed Research*, **39**, pp. 481–492.
- LAMM, R.D.; SLAUGHTER, D.C.; GILES, D.K. y LEE, W.S. (2006). «Development of a robotic weed control system for cotton». <http://baesil.engineering.ucdavis.edu/cotton.html>.
- LASE, LABORATORY OF AGRICULTURAL SYSTEMS ENGINEERING (2005). <http://mama.agr.okayamau.ac.jp/lase/tomato.html>.
- LEAKE, D. B. EDITOR (1996). *Case-Based Reasoning: Experiences, Lessons and Future Directions*. Menlo Park, CA; AAAI Press/MIT Press.

- LECHLER, GMBH (2009).. [Http://www.lechler-nozzles.co.uk/vario.html](http://www.lechler-nozzles.co.uk/vario.html).
- LEE, P.S. y DEXTER, A.L. (2001). «A Fuzzy Approach to Fault Diagnosis in the Presence of Sensor Bias». En: *FUZZ-IEEE 2001*, pp. 1585–1588.
- LEE, W.S.; SLAUGHTER, D.C. y GILES, D.K. (1996). «Development of a machine vision system for weed control using precision chemical application.» En: *Proceedings of International Conference on Agricultural Machinery Engineering '96*, pp. 802–811. Seoul, Korea.
- LEE, W.S.; SLAUGHTER, D.C. y GILES, D.K. (1999). «Robotic weed control system for tomatoes using machine vision and precision chemical application». *Precision Agriculture*, **1**, pp. 95–113.
- LEEMANS, V. y DESTAIN, M.-F. (2006). «Line cluster detection using a variant of the Hough transform for culture row localisation». *Image and Vision Computing*, **24**, pp. 541–550.
- LEEMANS, V. y DESTAIN, M.-F. (2007). «A computer-vision based precision seed drill guidance assistance». *Computers and Electronics in Agriculture*, **59**, pp. 1–12.
- LENZ, M.; BRITSCH-SPÖRL, B.; BURKHARD, H.-D. y WESS, S. (Eds.) (1998). *Case-Based Reasoning Technology: From Foundations to Applications*. Lecture Notes in Artificial Intelligence, Springer.
- LI, C.-T. y CHIAO, R. (2003). «Multiresolution genetic clustering algorithm for texture segmentation». *Image and Vision Computing*, **21**, pp. 955–966.
- LIAO, T. W.; ZHANG, Z. y MOUNT, C. R. (1998). «Similarity measures for retrieval in case-based reasoning systems». *Applied Artificial Intelligence*, **12**, pp. 267–288.
- LIVE, LABORATORY FOR IMAGE & VIDEO ENGINEERING (2009). <http://live.ece.utexas.edu/research/Quality>.
- LOGHAVI, M. y MACKVANDI, B.B. (2008). «Development of a target oriented weed control system». *Computers and Electronics in Agriculture*, **63**, pp. 112–118.
- LOWENGER-DEBOER, J. (2003). «Precision farming or convenience agriculture?» En: *Proceedings of the 11th Australian Agronomic Conference*, The Regional Institute, Ltd.

BIBLIOGRAFÍA

- LÓPEZ DE MÁNTARAS, R.; MCSHERRY, D.; BRIDGE, D.; LEAKE, D.; B., SMYTHS; S., CRAW; B., FALTINGS; MAHER, M.L.; COX, M.T.; FORBUS, K.; KEANE, M.; AAMODT, A. y WATSON, I. (2005). «Retrieval, reuse, revision, and retention in case-based reasoning». *The Knowledge Engineering Review*, **20**, pp. 215–240.
- LÓPEZ-GRANADOS, F.; JURADO-EXPÓSITO, M.; ATENCIANO NÚÑEZ, S.; GARCÍA-FERRER, A.; SÁNCHEZ DE LA ORDEN, M. y L., GARCÍA-TORRES (2002). «Spatial variability of agricultural soils in southern Spain.» *Plant and Soil*, **246**, pp. 97–105.
- LÓPEZ-GRANADOS, F.; JURADO-EXPÓSITO, J.M., M.AND PEÑA-BARRAGÁN y GARCÍA TORRES, L. (2005). «Using geostatistical and remote sensing approaches for mapping soil properties». *European Journal of Agronomy*, **23(3)**, pp. 279–289.
- LUSCHEI, E.C.; VAN WYCHEN, L.R.; MAXWELL, B.D.; BUSSAN, A.J.; BUSCHENA, D. y GOODMAN, D. (2001). «Implementing and conducting on-farm weed research with the use of GPS». *Weed Science*, **49**, pp. 536–542.
- MAIN, C. L.; ROBINSON, D. K.; MCELROY, J. S.; MUELLER, T. C. y WILKERSON, J. B. (2004). «A guide to predicting spatial distribution of weed emergence using geographic information systems (GIS)». <http://www.plantmanagementnetwork.org/pub/ats/guide/2004/gis/>.
- MAMDANI, E.H. y ASSILIAN, S. (1975). «An Experiment in Linguistic Synthesis with a Fuzzy Logic Controller». *International Journal on Human-Computer Studies*, **51**, pp. 135–147.
- MANDUCHI, R. (2006). «Learning Outdoor Color Classification». *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **28**, pp. 1713–1723.
- MARTÍNEZ, M.; BLASCO, X.; HERRERO, J.M.; RAMOS, C. y SANCHIS, J. (2005). «Monitorización y control procesos. Una visión teórico-práctica aplicada a invernaderos». *Revista Iberoamericana de Automática e Informática Industrial*, **2(4)**, pp. 5–24.
- McFARLANE, M.D. (1972). «Digital Pictures Fifty years ago». En: *Proceedings IEEE*, volumen 60, pp. 768–770.

- MEYER, G.E. y NETO, J.C. (2008). «Verification of color vegetation indices for automated crop imaging applications». *Computers and Electronics in Agriculture*, **63**, pp. 282–293.
- MICHALEWICZ, ZBIGNIEW (1996). *Genetic Algorithms + Data Structures = Evolution programs*. Springer Verlag.
- MICHEL, P.; CHESTNUTT, J.; KAGAMI, S.; NISHIWAKI, K.; KUFFNER, J. y KANADE, T. (2008). «GPU-accelerated Real-Time 3D Tracking for Humanoid Autonomy». En: *Proceedings of the JSME Robotics and Mechatronics Conference (ROBOMECH'08)*, .
- MIETTINEN, K.; NEITTAANMÄKI, P.; MÄKELÄ, M.M. y PÉRIAUX, J. (Eds.) (1999). *Evolutionary Algorithms in Engineering and Computer Science*. John Wiley & Sons, Inc, New York, NY, USA.
- MILLER, G.T. (2004). *Sustaining the Earth: An Integrated Approach*. Thompson Learning.
- MITCHELL, TOM M. (1997). *Machine Learning*. McGraw-Hill International Editions.
- MONACO, T.J.; GRAYSON, A.S. y SANDERS, D.C. (1981). «Influence of four weed species on the growth, yield, and quality of direct seeded tomatoes *Lycopersicon esculentum*». *Weed Science*, **29(4)**, pp. 349–397.
- NASA, JET PROPULSION LABORATORY (2008). <http://www-robotics.jpl.nasa.gov/index.cfm>.
- NCEA, NATIONAL CENTRE FOR ENGINEERING IN AGRICULTURE (2008). «A Coordinated Approach to Precision Agriculture RDE for the Australian Sugar Industry». *Informe técnico*, University of Southern Queensland.
- NORDMEYER, H. (2007). «The Potential of Herbicide Reduction in Site-Specific Weed Control». En: *Proceedings 2nd Conference on Precision Crop Protection*, .
- NORREMARK, M.; SOGAARD, H.T.; GRIEPENTROG, H.W. y NIELSEN, H. (2007). «Instrumentation and method for high accuracy geo-referencing of sugar beet plants». *Computers and Electronics in Agriculture*, **56**, pp. 130–146.
- OLSEN, H.J. (1995). «Determination of row position in small-grain crops by analysis of video images». *Computers and Electronics in Agriculture*, **12**, pp. 147–162.

BIBLIOGRAFÍA

- OMS, ORGANIZACIÓN MUNDIAL DE LA SALUD (1992). «Our planet, our health: Report of the WHO commission on health and environment». *Environment and Urbanization*, **4**, pp. 65–76.
- ONYANGO, C.M. y MARCHANT, J.A. (2003). «Segmentation of row crop plants from weeds using colour and morphology». *Computers and Electronics in Agriculture*, **39**, pp. 141–155.
- OTSU, N. (1979). «A threshold selection method from gray-level histograms». *IEEE Transactions on Systems, Man and Cybernetics*, **9**, pp. 62–66.
- PAICE, M.E.R. (2000). «Simulation modelling for the development of site-specific weed management systems». En: *Proceedings 3rd International Weed Science Congress*, pp. 178–188.
- PAICE, M.E.R. y DAY, W. (1997). «Using computer simulation to compare patch spraying strategies». En: *Proceedings 1st European Conference on Precision Agriculture*, pp. 421–428.
- PAICE, M.E.R.; DAY, W.; REW, L.J. y HOWARD, A. (1998). «A stochastic simulation model for evaluating the concept of patch spraying». *Weed Research*, **38**, pp. 373–388.
- PAJARES, G. y DE LA CRUZ, J. M. (2002). «Clasificación de texturas naturales mediante k-means». *Revista Electrónica de Visión por Computador*, **6**, pp. 1–18.
- PAJARES, G. y DE LA CRUZ, J. M. (2007). *Visión por Computador: imágenes digitales y aplicaciones*. RaMa Editorial.
- PAJARES, G. y SANTOS, M. (2005). *Inteligencia Artificial e Ingeniería del Conocimiento*. Ra-Ma Editorial, Madrid, España.
- PÉREZ, A.J.; LÓPEZ, F.; BENLLOCH, J.V. y CHRISTENSEN, S. (2000). «Colour and Shape Analysis techniques for weed detection in cereal fields». *Computers and Electronics in Agriculture*, **25**, pp. 197–212.
- PERNER, P. (1998). «Different Learning Strategies in a Case-Based Reasoning System for Image Interpretation». *Lecture Notes in Computer Science*, **1488**, pp. 251–262.
- PERNER, P. (1999). «An architecture for a CBR image segmentation system». *Engineering Applications of Artificial Intelligence*, **6**, pp. 749–759.

- PERNER, P. (2001). «Why Case-Based Reasoning Is Attractive for Image Interpretation». En: *D. Aha and I Watson (Eds.) Case-Based Reasoning Research and Development*, pp. 27–44.
- PERNER, P. (2006). «Case-based object recognition for airborne fungi recognition». *Artificial Intelligence in Medicine*, **36**, pp. 137–157.
- PERRY, J. N. (1997). «Measures of spatial pattern for counts». *Ecology*, **79**, pp. 1008–1017.
- PERRY, J. N. y LÓPEZ-GRANADOS, F. (1999). «Measuring the spatial pattern of *Orobanche crenata* weeds by SADIE red-blue analysis». En: *VII Conferencia Española de Biometría*, pp. 247–250. Palma de Mallorca, España.
- PERRY, N y LUTMAN, P. J. W. (2000). «Spatial population dynamics of patches of wild oats and alternative methods of mapping weeds». En: *1st Workshop of the EWRS Working Group Site-Specific Weed Management*, Odense, Denmark.
- PIERCE, F.J. y NOWAK, P. (1999). «Aspects of Precision Agriculture». *Advances in Agronomy*, **67**, pp. 1–85.
- PIKE, D.R.; STOLLER, E.W. y WAX, L.M. (1990). «Modeling soybean growth and canopy apportionment in weed-soybean *Glycine max*». *Weed Science*, **38**, pp. 522–527.
- PIRON, A.; LEEMANS, V.; KLEYNEN, O.; LEBEAU, F. y DESTAIN, M.-F. (2008). «Selection of the most efficient wavelength bands for discriminating weeds from crop». *Computers and Electronics in Agriculture*, **62**, pp. 141–148.
- POZO-RUZ, A.; RIBEIRO, A.; GARCÍA-ALEGRE, M.C.; GARCÍA, L.; GUINEA, D. y SANDOVAL, F. (2000). «Sistema GPS. Descripción, análisis de errores, aplicaciones y futuro». *Mundo Electrónico*, **306**, pp. 54–59.
- RADCLIFFE, N.J. y GEORGE, F.A.W. (1993). «A study in Set Recombination». En: *Proceeding of the Fifth International Conference on Genetic Algorithms*, pp. 23–30. San Mateo, Ca, USA.
- REID, J.F.; ZHANG, Q.; NOGUCHI, N. y DICKSON, M. (2000). «Agricultural automatic guidance research in North America». *Computers and Electronics in Agriculture*, **25**, pp. 155–167.

BIBLIOGRAFÍA

- REW, L.J. y COUSENS, R. (2001). «Spatial distribution of weeds in arable crops: are current sampling methods appropriate?» *Weed Research*, **41**, pp. 1–18.
- RIBEIRO, A.; DÍAZ, B. y GARCÍA-ALEGRE, M.C. (2003). «Extracting fuzzy rules to describe weed infestations in terms of soil factors». En: *Proceedings of the 12th IEEE International Conference on Fuzzy Systems*, volumen 2, pp. 1032–1037. St. Louis, USA. ISBN 0-7803-7810-5.
- RIBEIRO, A.; FERNÁNDEZ-QUINTANILLA, C.; BARROSO, J. y GARCÍA-ALEGRE, M. C. (2005). «Development of an Image Analysis System for Estimation of Weed.» En: *Proceedings 5th European Conf. On Precision Agriculture (5ECPA)*, pp. 169–174.
- RIBEIRO, A.; GARCÍA-ALEGRE, M.C.; GUINEA, D. y CRISTOBAL, G. (2000). «Automatic rules generation by GA for eggshell defect classification». En: *Proceedings of European Congress on Computational Methods in Applied Sciences and Engineering (ECCOMAS)*, Barcelona, Spain. ISBN 84-89925-69-0.
- RICH, E. y KNIGHT, K. (1991). *Artificial Intelligence*. McGraw-Hill International Editions.
- RIDER, T.W.; VOGEL, J.W.; DILLE, J.A.; DHUYVETTER, K.C. y KASTENS, T.L. (2006). «An economic evaluation of site-specific herbicide application». *Precision Agriculture*, **7(6)**, pp. 379–392.
- RIESBECK, C.K. y SCHANK, R. C. (1989). *Inside Case-Based Reasoning*. Northvale, NJ,USA: Erlbaum.
- RIZZARDI, K.; PROSTKO, E.; RAINS, G.; VELLIDIS, G. y MORARI, F. (2007). «Selective Spraying of Weeds in Peanut». En: *Poster Proceedings of the Sixth European Conference on Precision Agriculture (6ECPA)*, Eds. A.S. Blackmore, T. Gemtos, S. Fountas, Skiathos, Greece.
- ROBERTS, H.A.; HEWSON, R.T. y RICKETTS, M.A. (1977). «Weed competition in drilled summer lettuce». *Horticulture Research*, **17**, pp. 39–45.
- RODRÍGUEZ-DÍAZ, F. y BERENGUEL-SORIA, M. (2004). *Control y Robótica en Agricultura*. Universidad de Almería, Servicio de Publicaciones, Almería.

- RUDOLPH, G. (1994). «Convergence Analysis of Canonical Genetic Algorithms». En: *IEEE Transactions on Neural Networks, special issue on evolutionary computation*, volumen 5.
- RUIZ, D.; ESCRIBANO, C. y FERNANDEZ-QUINTANILLA, C. (2006). «Assessing the opportunity for site-specific management of *Avena sterilis* L. in winter barley fields in Spain». *Weed Research*, **46**, pp. 379–387.
- RUSS, J. C. (2002). *The Image Processing Handbook*. CRC Press, fourth^a edición.
- SARLE, W.; FAHLMAN, S.; PRECHELT, L. y PLATE, T. (1993). «Kangaroos, series of on-line articles». [Http://comp.ai.neural-nets](http://comp.ai.neural-nets).
- SENAY, G.B.; WARD, A.D.; LYON, J.G.; FAUSEY, N.R. y NOKES, S.E. (1998). «Manipulation of high spatial resolution aircraft remote sensing data for use in site-specific farming». *Transactions of the American Society of Agricultural Engineers*, **41**, pp. 489–495.
- SHYU, M-S. y LEOU, J-J. (1998). «A Genetic Algorithm Approach To Color Image Enhancement». *Pattern Recognition*, **31(7)**, pp. 871–880.
- SIERRA-ARAUJO, B. (2006). *Aprendizaje Automático: conceptos básicos y avanzados. Aspectos prácticos utilizando el software WEKA*. Pearson. Prentice Hall.
- SLAUGHTER, D.C.; D.K., GILES y DOWNEY, D. (2008). «Autonomous robotic weed control systems: A review». *Computers and Electronics in Agriculture*, **61**, pp. 63–78.
- SOGAARD, H.T. y OLSEN, H.J. (2003). «Determination of crop rows by image analysis without segmentation.» *Computers and Electronics in Agriculture*, **38**, pp. 141–158.
- SRINIVAS, N. y DEB, K. (1995). «Multi-Objective function optimization using non-dominated sorting genetic algorithms». *Evolutionary Computation*, **2(3)**, pp. 221–248.
- SRINIVASAN, A. (2006). *Handbook of Precision Agriculture. Principles and Applications*. The Haworth Press, New York.
- STAFFORD, J. V. (2000). «Implementing Precision Agriculture in the 21st Century.» *Journal of Agricultural Engineering Research*, **76**, pp. 267–275.

BIBLIOGRAFÍA

- STAFFORD, J.V y MILLER, P.C. (1993). «Spatially selective application of herbicides to cereal crops». *Computers and Electronics in Agriculture*, **9**, pp. 217–229.
- SURREALCOLOR (2009). <http://surrealcolor.110mb.com/IRexplainedweb/IRexplained.htm>.
- TALAVERA, NIDIA (2006). «Tecnología de aplicación de herbicidas». <http://www.abc.com.py/suplementos/rural/articulos.phppid=270981>.
- TANG, L.; TIAN, L.F.; STEWARD, B.L. y REID, J.F. (1999). «Texture-Based Weed Classification Using Gabor Wavelets and Neural Network for Real-time Selective Herbicide Applications». *Transactions of the American Society of Agricultural Engineers*, **99**, p. 7035.
- TELLAECHE, A.; BURGOS-ARTIZZU, X. P.; PAJARES, G. y RIBEIRO, A. (2008a). «A New Vision-based Approach to Differential Spraying in Precision Agriculture». *Computers and Electronics in Agriculture*, **60**, pp. 144–155.
- TELLAECHE, A.; BURGOS-ARTIZZU, X. P.; PAJARES, G. y RIBEIRO, A. (2008b). «A Vision-based Method for Weeds Identification Through the Bayesian Decision Theory». *Pattern Recognition*, **41**, pp. 521–530.
- THORP, K.R. y TIAN, L.F. (2004). «A Review on Remote Sensing of Weeds in Agriculture». *Precision Agriculture*, **5**, pp. 477–508.
- TIAN, L. (2002). «Development of a sensor-based precision herbicide application system». *Computers and Electronics in Agriculture*, **36**, pp. 133–149.
- TIAN, L.F.; REID, J.F. y HUMMEL, J.W. (1999). «Development of a precision sprayer for site-specific weed management.» *Transactions of the American Society of Agricultural Engineers*, **42**, pp. 893–900.
- TIAN, L.F. y SLAUGHTER, D.C. (1998). «Environmentally adaptive segmentation algorithm for outdoor image segmentation.» *Computers and Electronics in Agriculture*, **21**, pp. 153–168.
- TILLET, N.D. y HAGUE, T. (1999). «ComputerVisionbased Hoe Guidance for Cereals an initial trail». *Journal of agricultural Engineering Research*, **74**, pp. 225–326.

- TORII, T. (2000). «Research in autonomous agriculture vehicles in Japan». *Computers and Electronics in Agriculture*, **25**, pp. 133–153.
- TRIANANTAPHYLLOU, E. (2000). *Multi-criteria Decision Making Methods: a Comparative Study*. Kluwer Academic Publishers.
- UREÑA, R.; RODRÍGUEZ-DÍAZ, F. y BERENGUEL-SORIA, M. (2001). «A machine vision system for seeds germination quality evaluation using fuzzy logic». *Computers and Electronics in Agriculture*, **32**, pp. 1–20.
- VAN DER WEKEN, D.; NACHTEGAEL, M. y KERRE, E.E. (2004). «Using similarity measures and homogeneity for the comparison of images». *Image and Vision Computing*, **22**, pp. 695–702.
- VAN EVERT, F. K.; VAN DER HEIJDEN, G.W.A.M.; LOTZ, L.A.P.; POLDER, G.; LAMAKER, A.; DE JONG, A.; KUYPER, M.C.; GROENDIJK, E.J.K.; NEETESON, J.J. y VAN DER ZALM, T. (2006). «A Mobile Field Robot with Vision-Based Detection of Volunteer Potato Plants in a Corn Crop». *Weed Technology*, **20**, pp. 853–861.
- VAN HENTEN, E.J. y BONTSEMA, J. (1995). «Non Destructive Crop Measurements by Image Processing for Crop Growth Control». *Journal of Agricultural Engineering Research*, **61**, pp. 97–105.
- VEENMAN, C.J.; REINDERS, M.J.T. y BAKKER, E. (2003). «A Cellular Coevolutionary Algorithm for Image Segmentation». *IEEE Transactions on Image Processing*, **12**(3), pp. 304–316.
- VRINDTS, E. (2000). «Techniques for a more efficient use of herbicides in agriculture: developing a method to classify crop and weeds in field conditions based on spectral data». En: *Proceedings 1st Workshop of the EWRS Working Group Site-Specific Weed Management*, Odense, Denmark.
- WALLINGA, J. (1995). «The role of space in plant population dynamics: annual weeds as an example». *Oikos*, **74**, pp. 377–383.
- WANG, Y.H. (2003). «Image indexing and similarity retrieval based on spatial relationship model». *Information Sciences Informatics and Computer Science*, **154**, pp. 39–58.

BIBLIOGRAFÍA

- WANG, Z.; BOVIK, A.C.; SHEIKH, H.R. y SIMONCELLI, E.P. (2004). «Image Quality Assessment: From Error Visibility to Structural Similarity». *IEEE Transactions on Image Processing*, **13**(4), pp. 600–612.
- WEBSTER, T. M.; CARDINA, J. y WOODS, S. J. (2000a). «Spatial and temporal expansion patterns of *Apocynum cannabinum* patches». *Weed Science*, **48**, pp. 728–733.
- WEBSTER, T. M.; CARDINA, J. y WOODS, S. J. (2000b). «*Apocynum cannabinum* interference in no-till Glycine max.» *Weed Science*, **48**, pp. 716–719.
- WEINER, J. (1982). «A neighborhood model of annual plant interference.» *Ecology*, **63**, pp. 1237–1241.
- WOEBBECKE, D.M.; MEYER, G.E.; VONBARGEN, K. y MORTENSEN, D.A. (1995). «Color indices for weed identification under various soil, residue, and lighting conditions.» *Transactions of the American Society of Agricultural Engineers*, **38**(1), pp. 271–281.
- YANG, C.C; PRASHER, S.O. y LANDRY, J.A. (2002a). «Weed Recognition in Corn Fields using back-propagation neural network models». En: *Canadian Byosistems Engineering*, volumen 44, pp. 7.15–7.22.
- YANG, C.C; PRASHER, S.O.; LANDRY, J.A. y H.S., RAMASWAMY (2003). «Development of an image processing system and a fuzzy algorithm for site-specific herbicide applications.» *Precision Agriculture*, **4**, pp. 5–18.
- YANG, C.C; PRASHER, S.O.; LANDRY, J.A.; H.S., RAMASWAMY y DiTOMMASO, A. (2002b). «Application of artificial neural networks in image recognition and classification of crop and weeds». En: *Canadian Byosistems Engineering*, volumen 42, pp. 147–152.
- ZADEH, L.A. (1965). «Fuzzy Sets as a Basis for a Theory of Possibility». *Fuzzy Sets and Systems 100 Supplement (1999)*, pp. 9–34.
- ZADEH, L.A. (1973). «Outline of a new approach to the analysis of complex systems and decision processes.» En: *IEEE Transactions on Systems, Man & Cybernetics*, volumen 3, pp. 28–44.

- ZHANG, Z.; KODAGODA, S.; RUIZ, D.; KATUPITIYA, J. y DISSANAYAKE, G. (2008). «Classification of Bidens in Wheat Farms». En: *15th International Conference on Mechatronics and Machine Vision in Practice (M2VIP 2008)*, Auckland, New Zealand.
- ZHENG, L.; ZHANG, J. y WANG, Q. (2009). «Mean-shift-based color segmentation of images containing green vegetation». *Computers and Electronics in Agriculture*, **65**, pp. 93–98.
- ZITZLER, E. y THIELE, L. (1998). «Multiobjective optimization using evolutionary algorithms - a comparative case study». En: *Parallel Problem Solving from Nature*, pp. 292–301. Berlin, Germany: Springer.